



Universidad  
Carlos III de Madrid

**PROCESADO**

**AVANZADO DE SEÑAL**

**EMG**

**TRABAJO FIN DE GRADO**

*Universidad Carlos III de Madrid, Escuela politécnica superior*

**GRADO EN INGENIERÍA ELECTRÓNICA  
INDUSTRIAL Y AUTOMÁTICA**

**Tutor: Luis Enrique Moreno Lorente**

**Alumno: Álvaro Moreno Sanz**

*Leganés, Septiembre de 2017*



# ÍNDICE

1. INTRODUCCIÓN.....	9
1.1. OBJETIVOS .....	10
2. ANTECEDENTES CIENTÍFICOS .....	11
2.1. ELECTROMIOGRAFÍA (EMG) .....	11
2.1.1. Composición .....	13
2.1.2. Características .....	15
2.1.3. Influencias.....	15
2.2. ADQUISICIÓN.....	17
2.2.1. Electroodos.....	17
2.2.2. Colocación .....	18
2.2.3. Sistemas de adquisición y pre-procesamiento de la señal .....	19
2.3. EXTRACCIÓN DE ESTRATEGIAS NEURONALES A PARTIR DEL EMG SUPERFICIAL.....	21
2.3.1. Análisis indirecto .....	21
2.3.2. Análisis directo.....	25
2.4. ACONDICIONAMIENTO Y PROCESADO .....	26
2.4.1. Rectificado .....	26
2.4.2. Suavizado de la señal .....	27
2.4.3. Detección de movimiento.....	28
2.4.4. Espectro de la señal .....	30
2.4.5. Amplitud de la señal.....	31
2.4.6. Coeficiente de correlación cruzada .....	32
2.4.7. Clasificadores .....	33
3. METODOLOGÍA .....	35
3.1. MATERIAL EMPLEADO.....	35
3.2. PROCEDIMIENTO .....	35

4. RESULTADOS .....	38
4.1. FILTRADO .....	38
4.2. DETECCIÓN DE LA ACTIVACIÓN MUSCULAR.....	40
4.3. DESCOMPOSICIÓN .....	41
4.4. AMPLITUD .....	44
4.5. FRECUENCIA .....	46
4.6. CORRELACIÓN CRUZADA .....	49
4.7. CLASIFICACIÓN.....	51
5. DISCUSIÓN.....	55
6. CONCLUSIONES .....	58
7. REFERENCIAS .....	60
ANEXOS.....	64
A.1. PRESUPUESTO.....	64
A.2. TIEMPOS DE PROCESADO .....	64
A.3. CÓDIGO MATLAB .....	65

# ÍNDICE DE FIGURAS

<b>FIGURA 1.</b> RELACIÓN ENTRE EL SISTEMA NERVIOSO CENTRAL, PERIFÉRICO Y EL MÚSCULO.....	11
<b>FIGURA 2.</b> COMPOSICIÓN DE LA SEÑAL EMG. ....	12
<b>FIGURA 3.</b> SEÑALES OBTENIDAS MEDIANTE EMG INTRAMUSCULAR Y EMG SUPERFICIAL. ....	13
<b>FIGURA 4.</b> ELECTRODOS SECOS.....	18
<b>FIGURA 5.</b> ELECTRODOS HÚMEDOS.....	18
<b>FIGURA 6.</b> EFECTOS DE LA CANCELACIÓN DE AMPLITUD EN LA SEÑAL EMG. ....	23
<b>FIGURA 7.</b> DESCOMPOSICIÓN DE EMG SUPERFICIAL.....	25
<b>FIGURA 8.</b> INFLUENCIA DE LA RECTIFICACIÓN EN LA SEÑAL EN FUNCIÓN DEL NIVEL DE EXCITACIÓN. ....	27
<b>FIGURA 9.</b> PROCESO DE SUAVIZADO DE LA SEÑAL EMPLEANDO RMS CON VENTA DE 50 MUESTRAS. ....	28
<b>FIGURA 10.</b> CONSECUENCIAS DE LA ELECCIÓN DEL UMBRAL DE DETECCIÓN.....	30
<b>FIGURA 11.</b> PRINCIPIO DE APLICACIÓN DE LA TRANSFORMADA DE FOURIER DE TIEMPO REDUCIDO (STFT). ....	31
<b>FIGURA 12.</b> CORRELACIÓN CRUZADA ENTRE TRES SEÑALES. ....	32
<b>FIGURA 13.</b> INTERFERENCIAS DE 50 HZ EN LA SEÑAL RAW. ....	38
<b>FIGURA 14.</b> RESPUESTA DEL FILTRO BUTTERWORTH DE ORDEN 2.....	39
<b>FIGURA 15.</b> SEÑAL RAW SIN INTERFERENCIA DE 50 HZ .....	40
<b>FIGURA 16.</b> DETECCIÓN DE ACTIVACIÓN MUSCULAR DEL DEDO CORAZÓN. ....	41
<b>FIGURA 17.</b> DESCOMPOSICIÓN DE LA SEÑAL RAW DEL DEDO ANULAR. ....	42
<b>FIGURA 18.</b> DESCOMPOSICIÓN DE LA SEÑAL RAW DEL DEDO CORAZÓN. ....	42
<b>FIGURA 19.</b> DESCOMPOSICIÓN DE LA SEÑAL RAW DE AMBOS DEDOS COMBINADOS. ....	43
<b>FIGURA 20.</b> RESULTADOS DE LA DESCOMPOSICIÓN PARA EL DEDO CORAZÓN. ....	43
<b>FIGURA 21.</b> COMPARATIVA DE AMPLITUDES DE LOS DEDOS CORAZÓN Y ANULAR OBTENIDAS MEDIANTE RMS.....	44
<b>FIGURA 22.</b> AMPLITUD DE LA SEÑAL EMG DE CADA DEDO SOBRE EL FLEXOR DIGITORUM SUPERFICIALIS. .....	45
<b>FIGURA 23.</b> AMPLITUD RMS DE CADA DEDO PARA VARIOS MOVIMIENTOS.....	45

**FIGURA 24.** ACTIVACIÓN DETECTADA PARA CADA DEDO.....46

**FIGURA 25.** ANÁLISIS FRECUENCIAL DE LA SEÑAL RAW DEL DEDO CORAZÓN Y ANULAR PARA UNA MUESTRA DE 10 SEGUNDOS.....47

**FIGURA 26.** ANÁLISIS FRECUENCIAL DE LA SEÑAL RECTIFIED (RECTIFICADA Y FILTRADA) DEL DEDO CORAZÓN Y ANULAR PARA UN PERÍODO DE 10 SEGUNDOS.....48

**FIGURA 27.** STFT DEL DEDO CORAZÓN PARA UNA VENTANA DE 500 ms.....49

**FIGURA 28.** CORRELACIÓN CRUZADA PARA UNA ACTIVACIÓN DE CADA DEDO RESPECTO AL COMBINADO.....50

**FIGURA 29.** ENTRENAMIENTO DE CLASIFICADORES CON CLASIFICATION LEARNER APP.....52

**FIGURA 30.** MATRIZ DE CONFUSIÓN DEL CLASIFICADOR FINE GAUSSIAN SVM. ....53

**FIGURA 31.** CARACTERÍSTICAS PARA ENTRENAR AL CLASIFICADOR. ....54

# ÍNDICE DE TABLAS

<b>TABLA 1.</b> FACTORES QUE INFLUENCIAN EL EMG SUPERFICIAL. ....	16
<b>TABLA 2.</b> DESCRIPTORES FRECUENCIALES INFERIDOS. ....	49
<b>TABLA 3.</b> PRECISIÓN OBTENIDA SEGÚN EL MÉTODO DE CLASIFICACIÓN. ....	52
<b>TABLA 4.</b> PRESUPUESTO. ....	64





## 1. INTRODUCCIÓN

De entre las muchas aplicaciones de la robótica y el control automático, cabe destacar su importancia en el campo de la biomedicina. Hoy en día, la robótica juega un papel vital en la biomedicina, aportando los avances técnicos y aplicaciones que tienen como objetivo final la mejora en la calidad de vida de los pacientes.

Una de las muchas aplicaciones que la robótica provee a la medicina son los exoesqueletos y prótesis de miembro superior. En Europa, la incidencia de amputaciones de miembro superior va desde 50 a 270 anuales, con alrededor de 1.900 amputaciones traumáticas, haciendo un total de 94.000 amputados de miembro superior en la comunidad europea [1]. A lo largo de la historia, siempre ha existido la necesidad y el afán de sustituir un miembro amputado, ya sea por razones estéticas o funcionales. Las primeras prótesis de miembro superior encontradas datan del 1500 a.C. en Egipto. Eran prótesis sin funcionalidad, meramente estéticas. No fue hasta el siglo XIV y XV cuando se dotó de cierta funcionalidad a las prótesis, como ganchos contráctiles o mecanismos que movían los dedos al ser actuados con la otra mano. En 1948 se produjo un verdadero avance en el control de prótesis de miembro superior. Fue entonces cuando se empezó a usar la información extraída de la intención de movimiento de los amputados. Esta información se extraía mediante electrodos situados en la piel y registraban señales del sistema nervioso periférico del amputado.

A día de hoy, estas técnicas junto con otras más invasivas como la colocación de electrodos intramusculares, son las más empleadas para el control de prótesis activas de mano. A pesar de los grandes avances que se están produciendo en este campo durante los últimos años, replicar el complejo sistema motor y sensorial de la mano sigue siendo todo un desafío para la comunidad científica.

## 1.1. OBJETIVOS

El presente trabajo nace a raíz de la conferencia de biosistemas y biorrobótica “*Converging Clinical and Engineering Research on Neurorehabilitation II*”, a la cual asistió el tutor del trabajo, y en la que se planteó el tema “*The Quest for a Bionic Hand*”, donde se expusieron los últimos avances en el tratamiento de señales electromiográficas para el control de exoesqueletos de miembro superior. Para la elaboración del presente trabajo, se identificó una jerarquía de estudios relacionados con esta conferencia y se adaptó la forma en la que se toman las señales electromiográficas para adecuar la metodología a un trabajo final de grado.

El objetivo del trabajo se centrará en el tratamiento de datos obtenidos mediante electrodos superficiales situados en el antebrazo. Estos electrodos proporcionan una electromiografía (EMG), que muestra los impulsos eléctricos generados en los músculos durante las contracciones. Las señales EMG serán tratadas con el fin de estimar la señal de actuación del dedo anular o corazón. Con un correcto tratamiento de los datos obtenidos en el trabajo, se podría controlar un exoesqueleto de miembro superior.

Para conseguir diferenciar y estimar el movimiento del dedo corazón y anular se emplearán técnicas de procesamiento avanzadas de señales EMG.

La dificultad, y a la vez reto, del presente trabajo reside en conseguir diferenciar el movimiento de cada dedo y, a la vez, extraer estrategias neuronales a partir de estas señales EMG obtenidas con electrodos superficiales. Como veremos, en esta señal aparece información de la activación neuronal hacia los músculos. Si conseguimos tratar estos datos de la manera adecuada, con una simple prueba no invasiva se podría extraer información muy valiosa para diversas aplicaciones posteriores tanto a nivel funcional como en rehabilitación.

Por último, se hará un breve presupuesto de los recursos materiales empleados (se incluirá en los anexos del presente trabajo).


## 2. ANTECEDENTES CIENTÍFICOS

### 2.1. ELECTROMIOGRAFÍA (EMG)

La electromiografía es el estudio de las señales eléctricas del músculo generadas durante las contracciones de las fibras musculares. Para entender bien en qué consiste un EMG, es necesario conocer la fisiología que produce esa señal.

Las activaciones musculares del cuerpo son controladas mediante señales neuronales que van desde el sistema nervioso central (cerebro y médula espinal) hasta el sistema nervioso periférico (fibras nerviosas que conectan el sistema nervioso central con los órganos y músculos). Estas señales son conducidas por fibras nerviosas y reclutan diferentes fibras musculares.

La unidad mínima de contracción muscular es la unidad motora. Ésta está compuesta por una motoneurona, su axón y una serie de fibras musculares inervadas por el axón. Cada motoneurona realiza contactos sinápticos (aproximaciones funcionales que se realizan entre neuronas) con un número indeterminado de fibras musculares, que componen la unidad motora. Dependiendo del músculo donde se encuentra la unidad motora, ésta contendrá mayor o menor número de fibras musculares. Cuanto mayor sea el músculo, mayor será el número de fibras musculares que componen cada unidad motora. Podemos observar cada concepto explicado anteriormente de una forma más clara en la siguiente figura [2]:



**Figura 1.** Relación entre el sistema nervioso central, periférico y el músculo.

El sistema nervioso produce los diferentes niveles de contracción muscular de dos formas: Incrementando o reduciendo el número de unidades motoras reclutadas e incrementando o reduciendo la frecuencia del potencial de acción de cada unidad motora (la señal que se envía para su activación). El reclutamiento de unidades motoras sigue un orden de tamaño, empezando por las de poca resistencia a la fatiga y acabando por las de gran resistencia a la fatiga cuando la tensión es elevada [1].

El pulso registrado por cada unidad motora es lo que se conoce como potencial de acción. Una secuencia de estos pulsos se conoce como tren de potenciales de acción de unidad motora [3].

Así, un EMG compone la suma de todos estos trenes de potenciales de acción de unidad motora más una señal de ruido, que puede ser generada tanto por los instrumentos como por otros factores que serán explicados en capítulos posteriores. Se puede observar la composición de una señal EMG de una forma más gráfica en la siguiente figura [4]:

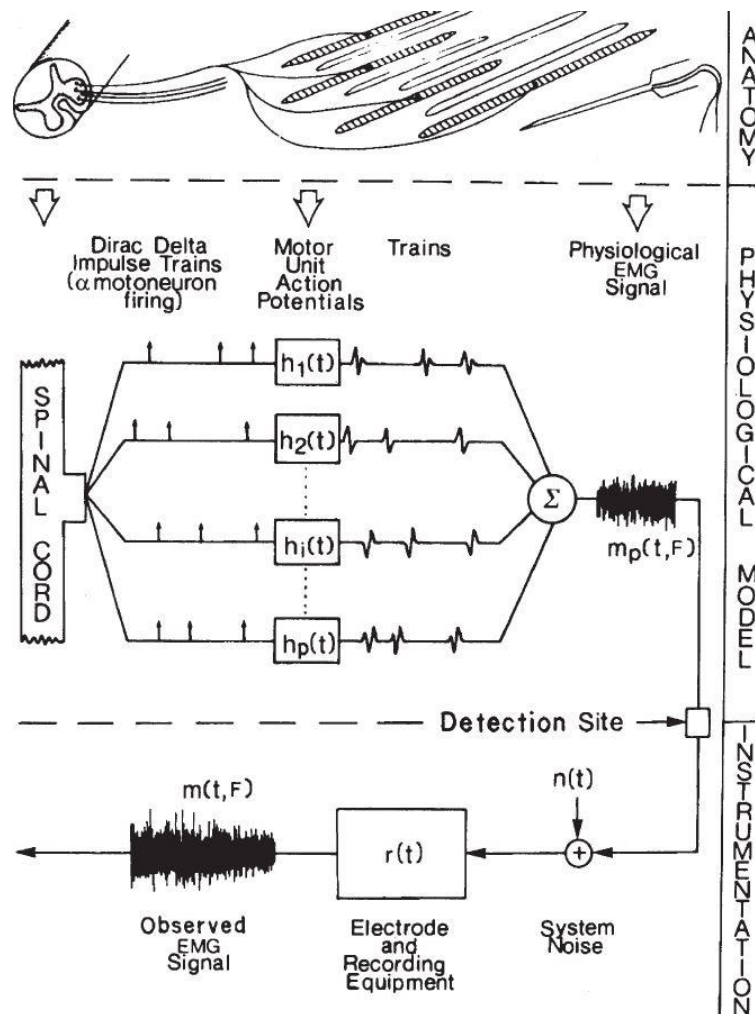


Figura 2. Composición de la señal EMG.

Existen multitud de formas de registrar señales EMG en función del tipo de electrodo que se emplea. Una clasificación en dos grandes grupos sería la siguiente: EMG superficial y EMG intramuscular.

El EMG superficial es un método no invasivo que emplea electrodos situados en la piel para medir la actividad eléctrica de las unidades motoras. Es un método altamente influenciado por características fisiológicas, anatómicas y bioquímicas, así como el número de unidades motoras activas y tipo de fibra muscular. También afecta el tipo de electrodos empleados, tecnología de procesamiento empleada y la colocación de los electrodos. La gran ventaja de este método frente a otros es su carácter no invasivo ya que no requiere cirugía para llevarlo a cabo.

Por otra parte, los EMG intramusculares son obtenidos usando electrodos interfasciculares insertados en los músculos seleccionados. Se trata de un método que ofrece información con menor ruido y más selectiva. Por contra, supone una técnica invasiva para el paciente ya que requiere de cirugía para la colocación de los electrodos.

En la siguiente figura podemos ver las diferencias entre señales obtenidas mediante electrodos intramusculares (arriba) y electrodos superficiales (abajo) [5]:



**Figura 3.** Señales obtenidas mediante EMG intramuscular y EMG superficial.

### 2.1.1. Composición

Una vez sabemos de donde proviene la señal EMG, debemos saber diferenciar la información que contiene. La señal EMG contiene información de dos tipos:

- Impulsos sinápticos recibidos por las neuronas motoras.
- Propiedades eléctricas de las fibras musculares.

Estos componentes los podemos ver en la siguiente ecuación, que describe una señal de EMG superficial:

$$S(t) = \sum_{i=1}^M \sum_{j=-\infty}^{+\infty} \varphi_i(t) \delta(t - t_{ij})$$

Donde  $S(t)$  es la señal EMG registrada,  $M$  es el número de unidades motoras activas,  $\delta(t - t_{ij})$  es la función delta que representa la descarga de una unidad motor en cierto tiempo de descarga,  $t_{ij}$ , y  $\varphi_i(t)$  es la forma del potencial de acción para la unidad motora (que muestra las propiedades eléctricas de las fibras musculares).

En este modelo, que por simplicidad no incluye ruido adicional, el tiempo de descarga,  $t_{ij}$ , de las neuronas motoras es determinado por la convergencia de impulsos sinápticos provenientes de múltiples fuentes del sistema nervioso central [6].

Si ahora miramos la señal EMG desde el punto de vista de procesamiento de señales, podemos definirla como un proceso estocástico coloreado no-estacionario. Se trata de una señal con componentes aleatorios, ruido y ancho de banda limitado, cuya amplitud es su desviación estándar, la cual es la raíz cuadrada de su potencia.

Si en la ecuación anterior asumimos que los trenes de potenciales de acción descargados por las neuronas motoras activas no están correlacionados, podemos obtener la amplitud,  $\sigma_{EMG}$ , (o desviación estándar) teóricamente y es la siguiente [6]:

$$\sigma_{EMG} = \sqrt{\sum_{i=1}^M DR_i E_i}$$

Donde  $DR_i$  es el ratio de descarga medio de la unidad motora  $i$  y  $E_i$  es la energía del potencial de acción de la unidad motora  $i$ .

En esta ecuación,  $DR_i$  representa la influencia de la conducción neuronal (es decir, la comunicación entre el sistema nervioso y el músculo) y  $E_i$  la contribución de las formas de los potenciales de acción.

De esta forma podemos sacar dos conclusiones respecto a la amplitud del EMG [6]:

- Incrementa cuando los ratios de descarga o el número de unidades motoras activas aumentan (lo cual está relacionado con la conducción neuronal hacia el músculo).
- Depende tanto de la conducción neuronal como de las propiedades de los potenciales de acción, sin posibilidad de distinguir entre ambos efectos.

### 2.1.2. Características

Si bien es cierto que las características de las señales EMG superficiales dependen del nivel y la duración de la contracción, del estado dinámico o estático del músculo, la fatiga y humedad de la piel [7], se podría generalizar y afirmar que un EMG superficial tiene las siguientes características [8]:

- Su valor instantáneo es aparentemente aleatorio siguiendo una distribución gaussiana en un rango de 10 – 500  $\mu$ Vrms.
- Sus armónicos se encuentran en frecuencias entre 10 – 400 Hz.
- La frecuencia principal del espectro se encuentra entre 70 – 130 Hz.
- La frecuencia media se encuentra entre 50 – 100 Hz.
- Si colocamos los electrodos convenientemente (en la misma dirección de las fibras musculares) podemos estimar la velocidad de propagación de la señal observando el retraso entre señales. Este valor es una estimación de la velocidad de conducción de la fibra muscular.

### 2.1.3. Influencias

Se puede llegar a extraer información muy valiosa de las señales EMG superficiales, si bien es cierto que estas señales están influenciadas por multitud de factores externos a la fisiología del paciente. Para conseguir maximizar la información obtenida, es necesario conocer los factores que influyen las señales de este tipo. Algunos de estos factores varían dependiendo de las condiciones experimentales. Otros, pueden ser minimizados con la colocación apropiada de los electrodos.

La siguiente tabla resume y muestra los factores, tanto fisiológicos como no-fisiológicos que influyen las señales EMG superficiales [9]:

**Tabla 1.** Factores que influyen en el EMG superficial.

<b>NO-FISIOLÓGICOS</b>	
Anatómicos	Forma del volumen del conductor Espesor de las capas de tejido subcutáneo Dishomogeneidad en el tejido Distribución de las unidades motoras en el músculo Tamaño de los territorios de UM Distribución y número de fibras en las UM Longitud de las fibras Dispersión de la unión de tendones con UM Dispersión de zonas de inervación sobre las UM Presencia de más de un ángulo de fijación
Sistema de detección	Contacto entre electrodo y piel (impedancia, ruido) Filtrado espacial para la detección de la señal Distancia entre electrodos Forma y tamaño de electrodos Colocación del electrodo respecto a las fibras musculares Colocación de los electrodos en el músculo
Geométricos	Acortamiento de las fibras musculares Cambio del músculo relativo al lugar de detección
Físicos	Conductividad del tejido Cantidad de diafonía de los músculos cercanos
<b>FISIOLÓGICOS</b>	
Propiedades de la fibra de las membranas	Velocidad de conducción media de la fibra muscular Distribución de las velocidades de conducción de las UM Distribución de vel. De cond. De fibras respecto UM Forma de potencial de acción intracelular
Propiedades de unidad motora	Número de UM reclutadas Distribución de ratio de descarga de UM Estadística y coef. De variación para ratio de descarga Sincronización entre unidades motoras



Uno de los factores no fisiológicos que condicionan en gran medida las señales EMG es la 'diafonía' (crosstalk). La diafonía en las señales EMG se refiere a la señal registrada sobre un músculo que es generada por otro músculo cercano y conducida a través del mismo volumen hacia los electrodos. Aunque muchos estudios apuntan a que el empleo de un filtro paso alto debería reducir la diafonía (ya que algunos investigadores sostienen que la señal lejana tiene un menor espectro), recientes investigaciones han demostrado que puede no tener ningún efecto en la diafonía [10]. Esto se debe a que la señal no-propagante que genera la diafonía contiene componentes de alta frecuencia mayores que los de la señal propagante. Muchos estudios apuntaban que era posible estimar la presencia de diafonía y reducirla mediante 'coeficientes de correlación cruzada' (cross-correlation coefficients) tal como sugirió Winter et al. [11], pero investigaciones más recientes desmienten que exista relación entre diafonía y coeficientes de correlación cruzada [10].

En los últimos tiempos, estudios experimentales y simulaciones han postulado las siguientes conclusiones respecto a la diafonía, que recogen Farina et al. [9]:

- Las señales registradas lejos de las fuentes son principalmente la extinción de los potenciales de acción al final de las fibras.
- Por las diferencias entre las señales de las fuentes propagantes y no-propagantes, el coeficiente de correlación cruzada generalmente no es un indicativo de la cantidad de diafonía.
- La frecuencia contenida en un EMG no identifica la presencia de diafonía.
- Filtros de paso alto en EMG superficiales pueden no reducir la diafonía.

Cabe destacar también que, debido a su gran selectividad y precisión, el fenómeno de la diafonía no se produce cuando se emplean electrodos intramusculares.

## **2.2. ADQUISICIÓN**


### **2.2.1. Electrodos**

Un electrodo superficial para EMG puede ser definido como un sensor de la actividad eléctrica de un músculo o un transductor de la corriente iónica fluyendo en el tejido, en la corriente electrónica y por los cables metálicos [12].

Un sensor de este tipo se caracteriza por diferentes parámetros, como forma, dimensiones, tecnología y materiales que lo constituyen.

Si los clasificamos según los materiales y tecnologías que se emplean para su fabricación, encontramos los siguientes tipos de electrodos:

- **Electrodos secos:** hay diferentes tipos, como los de pin o bola. Están hechos de metales nobles como oro, platino o plata.



**Figura 4.** Electrodos secos.

- **Electrodos húmedos:** son todos los que incluyen una capa de gel conductivo, hidrogel o esponja con solución electrolítica. Actúan como interface entre la piel y la parte metálica del electrodo. Normalmente son autoadhesivos por lo que son idóneos para la adquisición de EMG dinámicos. Se suelen emplear electrodos de plata-cloruro de plata ( $\text{Ag}/\text{AgCl}$ ). La gran ventaja de este tipo de electrodos es la alta estabilidad, el escaso ruido eléctrico y la baja impedancia.



**Figura 5.** Electrodos húmedos.

### 2.2.2. Colocación

Como hemos visto en anteriores secciones, hay muchos factores que perturban la señal EMG que se obtiene. Muchos de esos componentes pueden atenuarse e incluso eliminarse con una correcta colocación de los electrodos superficiales.

El año 1996 marca el inicio del proceso de estandarización de las metodologías empleadas en varios campos. Este proceso condujo a recomendaciones muy útiles respecto a los sensores y los procesos de colocación de los mismos, así como métodos de procesamiento de señal para EMG [1].

Según establece De Luca [13], los electrodos superficiales deben colocarse de la siguiente forma:

- El electrodo debe estar colocado entre un punto motor y la inserción del tendón o entre dos puntos motores y a lo largo de la línea mediana del músculo.
- No debe estar cerca o sobre el tendón del músculo, ya que las fibras musculares cerca del tendón son más escasas y pequeñas. También dificulta la colocación física del electrodo y se aumenta el riesgo de diafonía al estar más cerca de músculos antagonistas.
- No debe colocarse sobre el punto motor, ya que es el lugar más sensible ante cualquier activación muscular, lo que nos daría una señal muy inestable y ruidosa.
- No debe colocarse fuera de los bordes del músculo, ya que el electrodo puede detectar más fácilmente diafonía con otros músculos cercanos.
- El electrodo de referencia (o electrodo de tierra), que se emplea para que el preamplificador del electrodo tenga una referencia, debe ser colocado tan lejos como sea posible y en tejido neutro, situándose generalmente sobre el codo o sobre un hueso palpable.

### **2.2.3. Sistemas de adquisición y pre-procesamiento de la señal**

La señal que se obtiene de los electrodos en contacto con la piel es una señal débil y ruidosa que requiere una adecuación antes de poder ser tratada. Parte de esa adecuación se consigue empleando los correctos sistemas de adquisición. Las características del hardware empleado deben tener como objetivo maximizar la calidad de la señal EMG en términos de relación señal-ruido (signal to noise ratio, SNR).

A parte de los factores que afectan al SNR expuestos anteriormente, desde el punto de vista frecuencial podemos encontrar las siguientes perturbaciones [1]:

- Ruido en el equipo electrónico: desde 0 Hz hasta varios miles de Hz.
- Ruido ambiental: fuentes de radiación electromagnética a 50 Hz provenientes de las fuentes de alimentación.

- Artefacto de movimiento: interferencia generada durante el movimiento, generalmente entre el electrodo y el cable de 0 – 20 Hz.
- Inestabilidad en la señal. Entre 0 – 20 Hz.

Parte de este ruido puede ser eliminado o reducido empleando un correcto sistema de adquisición, especialmente en cuanto a electrodos y hardware.

De acuerdo con Micera et al. [1] las señales EMG serán adquiridas usando una cadena de uno o varios amplificadores de bajo ruido y alta impedancia de entrada y filtros. El amplificador instrumental es uno de los bloques de amplificación más común y usado para este fin.

Algunos valores tipo comerciales de estos componentes serán:

- Impedancia de entrada al menos 100 veces mayor que la impedancia mayor esperada entre el electrodo y la piel.
- Ruido del voltaje a la entrada entre  $1 - 60 \text{ nV}/\sqrt{\text{Hz}}$  a 1 kHz.
- Ruido de la corriente fluyendo en la impedancia electrodo-piel entre  $1 - 100 \text{ fA}/\sqrt{\text{Hz}}$  a 1 kHz.
- Rechazo al modo común entre 90 – 120 dB.

Después de la amplificación, las señales EMG son filtradas empleando bloques condicionantes de hardware o software. Se necesita un filtro paso alto para reducir los efectos de artefactos de movimiento e inestabilidad entre el electrodo y la piel. También se emplean filtros paso bajo para registrar de forma efectiva los datos correspondientes a estimulación muscular y eliminar interferencias a altas frecuencias. También se puede emplear un filtro paso banda aunando lo mencionado anteriormente.

Los valores típicos para los filtros recogidos en la literatura varían en función del estudio, pero se pueden obtener los siguientes valores típicos de acuerdo con Micera et al. [1]:

- Filtro paso alto con frecuencia de corte entre 10 – 20 Hz.
- Filtro paso bajo con frecuencia de corte entre 400 – 450 Hz.

Por último, es necesario emplear conversores de analógico a digital. Generalmente con frecuencias de muestreo de 1000 o 2000 Hz y con una tasa de 12, 16 ó 24 bits [12].

## **2.3. EXTRACCIÓN DE ESTRATEGIAS NEURONALES A PARTIR DEL EMG SUPERFICIAL**

Como hemos visto en capítulos anteriores, la señal EMG superficial contiene información neuronal sobre las señales que se envían desde la médula espinal para la activación del músculo. Dado que se trata de un método no invasivo y de muy fácil aplicación, tenemos una gran oportunidad para inferir información neuronal sin necesidad de emplear técnicas más complejas e invasivas. Esto abre un gran campo de estudio en el ámbito de las neurociencias. Por contra, al emplear una señal de EMG superficial será necesario mayor tratamiento de los datos y la selectividad y precisión de los resultados será menor que si se emplean técnicas más invasivas como los electrodos intramusculares.

Como veremos a continuación, se pueden emplear dos tipos de análisis para inferir estrategias neuronales a partir de señales EMG: Análisis indirecto y análisis directo [6].

### **2.3.1. Análisis indirecto**

Características como la amplitud de la señal EMG o su contenido frecuencial se han usado para inferir características neuronales tales como estrategias de reclutamiento de unidades motoras o intensidad de la conducción neuronal.

#### ***Análisis de amplitud:***

La amplitud ha sido empleada por muchos investigadores como un índice directo del nivel de activación que provee la médula espinal. La amplitud también está relacionada con la actividad de las unidades motoras y es a la vez la forma más básica para extraer información. No obstante, cabe destacar que en una señal EMG superficial la amplitud está altamente influenciada por los diversos factores mencionados en la tabla 1 (pg. 16). Por esta razón, para poder considerar la amplitud como una fuente fiable de información, será necesario un correcto tratamiento de los datos y una adecuada colocación de los electrodos.


Tal y como afirman Farina et al. [6], dado que la señal EMG tiene componentes aleatorios, su amplitud no puede ser definida con las características específicas de las formas de onda (como el valor de pico), sino que necesita estimaciones estadísticas tal y como hemos comentado anteriormente. Para calcular la amplitud del EMG, se pueden

emplear dos métodos: *Root mean-squared* (RMS) o *Average rectified value* (ARV). El RMS (que se desarrollará en capítulos posteriores) es el método más empleado por su claro significado físico, mientras que el ARV simplemente provee la medida del área bajo la señal EMG [13].

Al emplear la amplitud para inferir la conducción neuronal, debemos tener en cuenta que la amplitud de una señal EMG completa es siempre menor que la suma de las amplitudes de cada potencial de acción de cada unidad motora. Esto sucede debido a que las señales de las distintas unidades motoras se van solapando y las fases positivas y negativas de éstas se anulan y van reduciendo la amplitud de la señal. Esto es lo que se conoce como 'Cancelación de amplitud'. Este suceso debe tenerse en cuenta a la hora de analizar la amplitud de una señal EMG ya que puede limitar algunos métodos como la descomposición de señales.

En la siguiente figura [14] podemos ver de una forma más gráfica el efecto de la cancelación de amplitud. En la parte izquierda (A) se puede observar el efecto de la cancelación de amplitud en una señal EMG. Primero, los potenciales de acción de las unidades motoras son sumados y después rectificados (como ocurre con un EMG real). En la parte derecha (B) podemos ver de una forma teórica como quedaría una señal sin cancelación de amplitud. Para ello, se han rectificado primero las señales y después se han sumado. Esto es imposible hacerlo en un caso experimental, pero nos da una idea de la influencia de este fenómeno. Como se puede observar, la amplitud de la señal de la derecha (B) es mucho mayor a la de la izquierda (A).

*MU: unidad motora. au: unidades arbitrarias.*



**Figura 6.** Efectos de la cancelación de amplitud en la señal EMG.

Una de las conclusiones obtenidas en el estudio de Keenan et al. [14] es que, efectivamente, la cancelación de amplitud es un gran impedimento a la hora de extraer estrategias neuronales con señales EMG. Además, también señala que rectificar la señal no elimina la influencia de la cancelación de amplitud, si no que ésta será igual antes y después del rectificado. En un estudio reciente [15], se plantea un método eficaz para determinar la cantidad de cancelación de amplitud en una señal EMG.

La amplitud también se ha usado como indicativo para estimar la fuerza de un músculo. No obstante, dado que depende del número de unidades motoras reclutadas, del ratio de descarga de cada una y de los factores mencionados en la tabla 1 (pg. 16), no es posible realizar una relación general entre la amplitud del EMG y la fuerza del músculo. Por lo tanto, esta relación debería hacerse sujeto a sujeto y músculo a músculo independientemente [9].

### **Análisis frecuencial:**

Otro de los métodos indirectos se basa en el uso del espectro de la señal EMG rectificada, ya que rectificar la señal EMG no afecta a sus propiedades frecuenciales. Cabe destacar que cuando realizamos análisis frecuenciales de una señal EMG no estamos teniendo en cuenta la cancelación de amplitud mencionada anteriormente y por ese motivo los resultados podrían variar.

Uno de los usos más comunes del análisis frecuencial en señales EMG es determinar la fatiga en contracciones musculares isométricas bajo condiciones conocidas.

Por otra parte, lo que se puede observar si miramos el espectrograma de un EMG superficial son picos en frecuencias bajas (20 – 50 Hz). Estos picos indican el ratio medio de descarga de las unidades motoras activas (o frecuencia de disparo). Estos picos también se presentan en frecuencias múltiplo de la frecuencia de descarga. Hay que mencionar que la frecuencia de disparo de una unidad motora no se produce a un intervalo constante, sino que debe medirse en diferentes intervalos y obtener la media de todos ellos [16].

Por otra parte, una de las limitaciones de emplear análisis frecuencial en los EMG superficiales es que no se pueden inferir detalles sobre el reclutamiento de unidades motoras. Muchos estudios se basaban en el hecho de que la velocidad de conducción de las fibras musculares (asociada a distintas propiedades de las unidades motoras) era proporcional al espectro del EMG, es decir, velocidades de conducción pequeñas eran asociadas con menores frecuencias en el espectro. No obstante, en investigaciones recientes se ha demostrado que esta aproximación puede ser errónea ya que depende de la fisiología y tipo de unidad motora, de la influencia intracelular en la forma del potencial de acción y del volumen del conductor [6]. Si bien es cierto que emplear el análisis frecuencial para distinguir entre tipos de unidades motoras era un método muy empleado en el pasado, cada vez más estudios demuestran sus limitaciones y por ello su aplicación se ha visto reducida en los últimos años.


### **Otros análisis**

El uso de otros análisis como los métodos de coherencia y correlación cruzada entre señales EMG también son empleados para inferir estrategias neuronales a partir de señales EMG superficial. Estos métodos pueden realizarse entre encefalografías y EMG (ECG – EMG) o entre dos señales EMG (EMG – EMG). Este tipo de análisis indican la activación sináptica común para dos músculos distintos. También se pueden analizar dos señales del mismo músculo para ver la representación de su activación común, atenuando componentes independientes de la señal. Su aplicación y limitaciones pueden verse en detalle en el estudio realizado por Farina et al. [6].



### 2.3.2. Análisis directo

El análisis directo consiste en descomponer la señal EMG en los trenes de potenciales de acción de unidad motora. Como hemos visto en los primeros capítulos, la señal EMG se compone de la suma de todos estos trenes. Con un correcto algoritmo de descomposición, podemos llegar a obtener la forma de los distintos potenciales de acción de cada unidad motora y, por tanto, inferir información neuronal a partir de una señal de EMG superficial. En la siguiente figura se puede observar de una forma más clara lo que se pretende mediante el análisis directo [17]:



**Figura 7.** Descomposición de EMG superficial.

Si bien es cierto que es posible lograr una descomposición fiable, precisa y completa de una señal EMG superficial, es necesario conocer las limitaciones que cada algoritmo y material empleado plantean.

Una señal EMG puede ser registrada en uno o varios canales. En lo que a la descomposición de la señal se refiere, cuantos más canales sean usados para registrar el EMG, mayor será el número de unidades motoras que podremos detectar, haciendo posible que se pueda llevar a cabo una descomposición correcta y fiable. En consecuencia, el material más idóneo para registrar señales EMG superficiales con el fin de descomponerlas sería el uso de matrices de electrodos de alta densidad (pueden contener más de un centenar de electrodos).

De esta forma, cada vez más, los estudios actuales se centran en este tipo de matrices de electrodos para obtener datos más completos y representativos como fuerza de

músculos, ajustes musculares durante las fatigas o detalles sobre arquitecturas musculares.

Los algoritmos de descomposición más empleados se basan en la coincidencia de plantillas de potenciales de acción de unidad motora. Este método puede dividirse en tres pasos [18]: 1) Segmentación del EMG en formas de ondas distinguibles, 2) identificación de plantillas de potenciales de acción de unidad motora, 3) agrupación de las plantillas identificadas con las formas de onda idénticas a ellas.

A continuación puede verse un ejemplo de como actúa un algoritmo de descomposición [6]:

Un EMG superficial de un solo canal es descompuesto identificando el pico en la señal, extrayendo el segmento de señal alrededor de ese pico y detectando todas las otras veces que el segmento extraído se correlaciona con la señal respecto a un umbral de correlación prefijado. Las veces que la correlación supera el umbral es asumido como la descarga de una unidad motora por el algoritmo. Es más, la forma del potencial de acción de unidad motora es estimada ponderando la señal sobre las descargas identificadas. Estos pasos son aplicados de forma iterativa al residuo de la señal hasta que se alcanza un umbral también preestablecido.

En cuanto a los algoritmos empleados para la descomposición de las señales, es necesario una validación que indique la precisión y exactitud de cada uno. El problema de las señales EMG superficiales es que los potenciales de acción de unidades motoras se solapan continuamente, haciendo más dificultosa su descomposición. Este hecho no solo dificulta la descomposición de los EMG superficiales, sino que además hace que la elección de un método de descomposición validado sea crucial. Es tal la complejidad en la descomposición de una señal EMG que ésta no puede ser descompuesta manualmente como puede hacerse con los EMG intramusculares.

## **2.4. ACONDICIONAMIENTO Y PROCESADO**

### **2.4.1. Rectificado**


La señal EMG obtenida mediante los electrodos, después de ser amplificada y pre-filtrada (como se ha visto en el capítulo pre-procesamiento), es lo que se conoce como 'Raw EMG' (EMG "crudo"). Las señales Raw contienen información muy útil, pero en un formato muy confuso, ya que varía entre sujetos e incluso en el mismo sujeto en función de la posición los electrodos. Es muy común que el siguiente paso consista en rectificar

esta señal, es decir, en obtener el valor absoluto de la señal Raw. Es útil trabajar con la señal rectificada para, por ejemplo, analizar la amplitud.

La rectificación de la señal puede ser de dos tipos: De media onda, en la cual se descartan los valores negativos y sólo se tienen en cuenta los positivos, o de onda completa, en la cual se obtiene el valor absoluto de los valores negativos. La rectificación de onda completa es preferible para el posterior análisis.

También se ha empleado la rectificación de la señal EMG para detectar más fácilmente las frecuencias bajas (indicativo de la frecuencia de disparo de las unidades motoras) ya que estas frecuencias no son fácilmente detectables [19]. Si bien es cierta esta afirmación, hay casos en los que esta técnica puede provocar que se detecten picos a bajas frecuencias que no están relacionados con el ratio de descarga. Esto sucede cuando el nivel de excitación del movimiento es muy alto.

En la siguiente figura se puede observar el fenómeno descrito [9]:




**Figura 8.** Influencia de la rectificación en la señal en función del nivel de excitación.

#### 2.4.2. Suavizado de la señal

Una vez tenemos la señal rectificada, es útil realizar un suavizado si la queremos emplear para realizar estudios de amplitud. El suavizado de la señal eliminará (o al

menos reducirá muy significativamente) picos indeseados y extraerá la tendencia principal de la señal. Obtendremos así, la envolvente de la señal EMG.

Se pueden emplear varios algoritmos para el suavizado, como *moving average* (MA), que calcula la media en una ventana predefinida y la va moviendo por toda la señal. Otro método es el *Root mean-squared* (RMS), el cual va realizando la media cuadrática de los valores en un segmento predefinido que recorre toda la señal. El tamaño del segmento se suele situar entre 50 – 100 ms dependiendo del tipo de movimiento. También se pueden emplear filtros paso bajo con frecuencias de corte de 3 – 6 Hz para obtener la envolvente de la señal. El RMS es el método preferido y más usado para el suavizado de señal [20]. Como hemos visto, también nos ofrecerá información valiosa sobre la amplitud. En la siguiente figura podemos ver un ejemplo de suavizado.



**Figura 9.** Proceso de suavizado de la señal empleando RMS con venta de 50 muestras.

En este caso no sería necesario rectificar la señal antes de aplicar el RMS, ya que como veremos después, la señal se rectifica al aplicar RMS ya que sus componentes se elevan al cuadrado.

### 2.4.3. Detección de movimiento

El siguiente paso en el tratamiento de señal es emplear alguna técnica para detectar el momento en el que se produce el movimiento. La detección de la activación del músculo y la fuerza que éste ejerce son características que podrían ser extraídas analizando la

amplitud del EMG, siempre y cuando se haga en contracciones isométricas controladas [5]. Existen diferentes alternativas al método más básico, siendo este una inspección ocular al EMG por un observador experimentado. Estas alternativas han ido mejorando y ganando eficacia a lo largo de los años, pero a coste de una carga computacional mucho más elevada.


En primer lugar tenemos el 'método del umbral simple' (single threshold), que consiste en comparar la amplitud de la señal EMG rectificada con un valor umbral prefijado cuyo valor depende de la potencia del ruido de fondo. Es el método más intuitivo y común para detectar la actividad de contracción del músculo. Existe la posibilidad de que el ruido en ocasiones esté por encima de la señal de activación y se detecte un falso movimiento. En 1984 se planteó un sistema más robusto basado en un umbral doble y por último, en 2004 se propusieron mejoras basadas en el umbral doble que lo hacían más preciso y fiable, pero a costa de una mayor carga computacional [21].

Bonato et al. [22] proponen un sistema de detección basado en un umbral doble seguido de un post-procesamiento que rechaza activaciones de menos de 30 ms, lo cual hace que no se detecten numerosos flancos consecutivos para la misma activación muscular.


La elección de un umbral afecta al tratamiento de la señal. Un umbral muy bajo implica que sea más sensible y pueda detectar el ruido de fondo como una falsa activación. Por el contrario, un umbral alto implica que sea menos preciso a la hora de detectar movimientos más finos [23].

En un estudio reciente [24] se analizan diferentes umbrales de detección para señales EMG y se concluye que no es posible dar un valor concreto y fijo para el umbral debido a la variabilidad en las señales EMG, si no que se anima a los investigadores a justificar el umbral elegido antes de realizar el análisis de la señal.

A continuación podemos observar las consecuencias ante la elección de un umbral bajo (línea discontinua) frente a uno alto (línea continua) [23]:



(c) Low pass filtered EMG signal

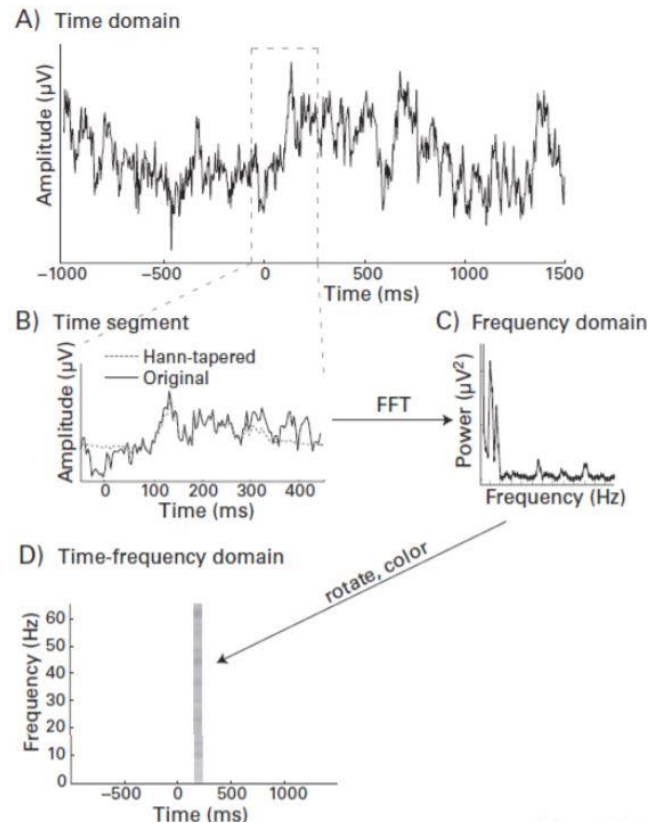


(d) Threshold-based detection of movement

**Figura 10.** Consecuencias de la elección del umbral de detección.

#### 2.4.4. Espectro de la señal

La señal EMG contiene información espectral que puede ser relevante para extraer diferentes características. Un método rápido para hacernos una idea del contenido frecuencial de una señal EMG consiste en aplicar la transformada rápida de Fourier (FFT). Si bien es cierto que una señal EMG se caracteriza por ser no-estacionaria, podríamos obtener el contenido frecuencial en cada momento y así observar los cambios que se van produciendo empleando la transformada de Fourier de tiempo reducido (STFT). Es el análisis tiempo-frecuencia más simple y el que requiere la menor carga computacional. A continuación podemos observar como funciona de una forma más detallada la STFT [25]:



**Figura 11.** Principio de aplicación de la transformada de Fourier de tiempo reducido (STFT).

### 2.4.5. Amplitud de la señal

Como hemos visto en anteriores capítulos, la amplitud de una señal EMG no puede ser definida con las características normales de las señales (valor de pico), sino que la amplitud debe ser definida con indicadores estadísticos. La amplitud de una señal EMG dependerá tanto de la cantidad de unidades motoras activas como del ratio de descarga de las mismas, por lo que podemos inferir información de ambas características. Como hemos comentado anteriormente, el *Root mean-squared* (RMS) no sólo es la técnica más empleada para suavizar la señal, sino que es uno de los métodos que nos ofrece información directa de la amplitud de una señal EMG. El RMS de una señal se obtiene con un segmento móvil que se desplaza por cada porción de la muestra y realiza su media cuadrática. La suma de estas medias determinará la amplitud en cada una de estas porciones. De este modo se puede obtener la amplitud de la señal EMG acorde con su carácter no-estacionario.

A continuación podemos ver la ecuación del RMS:


$$RMS_K = \sqrt{\frac{1}{N} \sum_{i=1}^N X_i^2}$$

Donde K es el número de segmento, N es la longitud del segmento y  $X_i$  es el valor de la señal en la parte  $i$  del segmento.

#### 2.4.6. Coeficiente de correlación cruzada

Otro de los métodos empleados en tratamiento de señales EMG para movimientos dinámicos es la correlación cruzada (Cross-correlation). Con este método podemos obtener información sobre la sincronización de unidades motoras en diferentes músculos, del mismo músculo en diferentes muestras e incluso entre diferentes sujetos. El principio por el que se rige la correlación cruzada consiste en comparar dos vectores (o señales) y encontrar similitudes entre ellos para diferentes momentos. Es decir, con una señal de muestra conocida se va recorriendo otra señal (retrasando una respecto a la otra) y va indicando en cada momento del retraso la similitud entre ambas. Un pico en la correlación cruzada indica una similitud elevada entre las señales. De esta forma se podría cuantificar la magnitud de cualquier elemento común a dos señales.

En la siguiente figura se puede observar un ejemplo de correlación cruzada en una señal EMG [26]:



**Figura 12.** Correlación cruzada entre tres señales. La primera muestra una gran semejanza mientras que en las otras la semejanza va reduciéndose.



Varios estudios emplean la correlación cruzada para determinar la diafonía entre dos señales [11], pero otros han demostrado y niegan categóricamente cualquier relación entre diafonía y correlación cruzada [27].

Por lo tanto, el uso de coeficientes de correlación cruzada es útil para encontrar patrones en señales EMG de movimientos dinámicos. Es más, se ha demostrado la consistencia a la hora de detectar patrones para varias sesiones en las que el paciente debía caminar. Incluso después de recolocar los electrodos, así como antes y después de una operación, los resultados de correlación cruzada siguen siendo consistentes [28].

Otra medida que se puede obtener de la correlación cruzada es el tiempo de descarga de las unidades motoras. Con una ventana de 150 – 400ms y cuantificando el pico en la correlación cruzada para el momento de retraso 0, podríamos obtener la señal sináptica común [18].

Del mismo modo, se puede deducir información en el dominio de la frecuencia empleando la correlación cruzada frecuencial. De este modo obtendríamos la similitud frecuencial entre dos señales dadas.

#### **2.4.7. Clasificadores**

Una vez se ha obtenido toda la información posible de la señal, es necesario clasificarla para poder tratar con ella.

Como hemos visto, debido a la complejidad de una señal EMG superficial, la información extraída puede ser tediosa y difícil de tratar. Por ello, para su clasificación, se emplean algoritmos complejos que tienen en cuenta el carácter y la naturaleza de una señal EMG. Del mismo modo, un clasificador debe ser rápido y preciso, ya que puede emplearse para aplicaciones en tiempo real.

Podríamos establecer una división entre los tipos de clasificadores empleados para las señales EMG: los basados en reconocimiento de patrones y los no basados en reconocimiento de patrones [1].

Entre los clasificadores más usados para señales EMG basados en el reconocimiento de patrones se encuentran los basados en redes neuronales (NN), análisis de discriminación lineal (LDA), NeuroFuzzy, Modelos gaussianos (GMM) o máquinas de vectores de soporte (SVM). Desde el año 1999 se empezaron a emplear algunos de estos clasificadores, y combinándolos con diferentes características tanto temporales

como frecuenciales, se han logrado obtener precisiones del 99% para clasificaciones de movimientos en los miembros superiores [29].

Por otro lado, los no basados en reconocimientos de patrones emplean técnicas como control proporcional, control de umbral, análisis de comienzo y máquinas de estados finitos (FSM).

No es posible generalizar sobre las ventajas o inconvenientes de cada clasificador, ya que la precisión depende tanto de las características que se han obtenido de las señales como del tipo de señal que se trata. Son muchos los estudios que comparan entre métodos de clasificación atendiendo a diferentes parámetros, por lo tanto, es conveniente probar diferentes clasificadores hasta encontrar el idóneo para los fines de cada estudio.

### 3. METODOLOGÍA

#### 3.1. MATERIAL EMPLEADO

Las muestras fueron adquiridas y pre-procesadas empleando el sistema avanzado de prototipado rápido, ARCP (advanced rapid control prototyping), de Flores Caballero et al. [30] junto con el sistema de adquisición electromiográfica de la UC3M.

Las ventajas que ofrece el sistema ARCP es que permite al usuario centrarse en las tareas de programación sin tener que ocupar el tiempo configurando dispositivos o realizando programación a bajo nivel. Gracias a que hace posible realizar una programación gráfica, es posible emplear el sistema de una forma muy versátil para cualquier plataforma de control. El sistema ARCP junto con Matlab (the MathWorks, USA) nos provee de una herramienta muy potente para el tratamiento de señal del presente trabajo.

En cuanto a la adquisición de las señales EMG, estas fueron obtenidas mediante la colocación de tres electrodos de plata-cloruro de plata (Ag/AgCl). Dos fueron colocados sobre el flexor digitorum superficialis (situado en la parte posterior del antebrazo) y el tercero, de referencia, sobre el codo. La salida de los sensores fue conectada al sistema de adquisición electromiografía propio de la UC3M. Éste emplea un amplificador diferencial de alta sensibilidad, que consta de dos amplificadores operacionales en configuración diferencial. Gracias a esta configuración diferencial, se consigue una respuesta muy buena ante el ruido externo.

La salida diferencial de este amplificador pasa por un conversor A/D de 24 bits con una frecuencia de muestreo de 1000 Hz.

#### 3.2. PROCEDIMIENTO

En el presente trabajo se parte de señales EMG superficiales registradas con el material mencionado anteriormente y se realiza un tratamiento “off-line” de ellas. Se obtendrán cuatro grupos de muestras en función del movimiento:

- Dedo anular.
- Dedo corazón.
- Movimiento combinado (Anular y corazón).
- Reposo (sin mover ningún dedo).

Todos los movimientos se han realizado de forma rápida y completa.

La duración completa de cada muestra de EMG es de 160 segundos y los datos se encuentran almacenados en formato *.mat* para poder ser tratados con Matlab. Usaremos la versión de Matlab R2016b (9.1.0.441655) 64-bit (Win 64) con licencia académica. Las señales obtenidas son de un canal.

Se obtendrán tres tipos de datos para cada movimiento:

- Raw: Datos filtrados con filtro paso banda de 20 a 400 Hz.
- Rectified: Valor absoluto de Raw.
- Filtered: valores filtrados con un filtro paso bajo de 20 Hz.

Se procesarán los datos mencionados de la siguiente manera, siempre teniendo en cuenta las limitaciones que tanto los métodos como las muestras plantean:

Se empezará procesando la señal del dedo anular y se extraerá toda la información posible para su posterior identificación en la señal de movimiento combinado. Del mismo modo sucederá con la señal del dedo corazón. La señal de reposo servirá para analizar características comunes a todas las señales a nivel de ruido de fondo.

Las señales serán visualizadas empleando la transformada rápida de Fourier (FFT) y después filtradas en función de las distorsiones que se observen.

A continuación se tratará de obtener información de las señales mediante el análisis directo (descomposición) expuesto en el apartado anterior. De entre todos los algoritmos disponibles para este fin, emplearemos dos métodos de descomposición cuyos algoritmos se encuentran implementados en un programa compatible con Matlab. El primero es EMGLAB [31] cuyo algoritmo interactivo ha sido validado por McGill y Lateva [32]. El segundo método se emplea para la descomposición de señales intramusculares de EMG [33]. Ajustando los parámetros de descomposición (sensibilidad del algoritmo y el ajuste con las plantillas de potenciales de acción de unidad motora) podríamos obtener resultados satisfactorios para señales de EMG superficial. Otros métodos de descomposición no han sido tenidos en cuenta ya que requerían de un mayor número de canales de la señal EMG en la entrada del algoritmo.

Después de emplear los análisis directos pasaremos a emplear los análisis indirectos, donde estudiaremos la amplitud con RMS y la frecuencia tanto con FFT como con STFT para tratar de inferir estrategias neuronales a partir de señales de EMG superficial. Con la amplitud se espera obtener información acerca de la activación muscular, duración y valores máximos, con el objetivo de comparar los diferentes movimientos. Además, obtendremos características neuronales como la conducción neuronal y número y

actividad de unidades motoras. Por otro lado, con el análisis frecuencial esperamos obtener el ratio medio de descarga de las unidades motoras activas durante el movimiento. Se emplearán también coeficientes de correlación cruzada entre las diferentes señales.

Por último, utilizando la información obtenida en los procesos indicados anteriormente, se procederá a diferenciar la señal de activación de un dedo u otro en la señal combinada empleando el método de clasificación que resulte más preciso.


También se comentarán los resultados obtenidos en posteriores capítulos. Se analizará si son coherentes respecto a la bibliografía empleada y, en caso de que no sean coherentes, se tratará de aportar una justificación al respecto.

## 4. RESULTADOS

### 4.1. FILTRADO

Como hemos visto en capítulos anteriores, son muchos los factores que influyen en una señal EMG. Algunos de estos factores pueden ser reducidos o eliminados con una buena colocación de los electrodos. Otros pueden eliminarse o reducirse con un posterior filtrado de las señales obtenidas.


Al realizar la transformada rápida de Fourier (FFT) se observa un pico indeseado a 50 Hz, propio de las fuentes electromagnéticas (como ordenadores, líneas de alimentación o iluminación). Es normal esperar esta interferencia, ya que la señal se encuentra filtrada con un paso banda de 20 a 400 Hz, por lo que sí descarta interferencias debidas a artefactos de movimiento o a altas frecuencias, pero no las debidas a fuentes electromagnéticas de 50 Hz. En la siguiente figura se puede ver la interferencia de 50 Hz en una muestra del dedo anular de 30 segundos de duración:




**Figura 13.** Interferencias de 50 Hz en la señal Raw.

Para tratar de eliminar esta interferencia, existen varios tipos de filtros (Notch, Butterworth, Savitzky-Golay...). La elección del filtro no es trivial, pues es probable que al eliminar la frecuencia de 50 Hz podemos también perder información en frecuencias

cercanas a ella. Es fundamental que la banda de bloqueo sea mínima para no perder información propia del EMG, ya que 50 Hz se encuentra en la banda de trabajo de una señal EMG. En este caso emplearemos un filtro Butterworth de orden 2 con frecuencia de bloqueo entre 49 y 51 Hz. De ese modo perderemos la mínima información alrededor de la frecuencia que nos interesa eliminar. Gracias al filtro Butterworth conseguimos también mantener bien definido el contenido espectral en cada periodo corto de tiempo [34]. En las siguientes figuras se pueden ver la respuesta del filtro así como la señal una vez filtrada.



**Figura 14.** Respuesta del filtro Butterworth de orden 2.




**Figura 15.** Señal Raw sin interferencia de 50 Hz.

Aunque se continúan apreciando ruidos propios de la propia naturaleza aleatoria de la señal EMG, podemos observar como se ha eliminado con éxito la interferencia de 50 Hz sin apenas perder información alrededor de la misma.

## 4.2. DETECCIÓN DE LA ACTIVACIÓN MUSCULAR

Teniendo en cuenta lo mencionado en capítulos anteriores, emplearemos el método del umbral simple para detectar las activaciones. Partiendo de la señal filtrada, rectificada y suavizada, se establece el umbral para cada dedo a partir del ruido de fondo detectado. El umbral será cinco veces la media del ruido de fondo. De este modo se obtendrán las activaciones para cada dedo. En la siguiente figura se observa el resultado para una muestra de 100 segundos del dedo corazón:





**Figura 16.** Detección de activación muscular del dedo corazón.

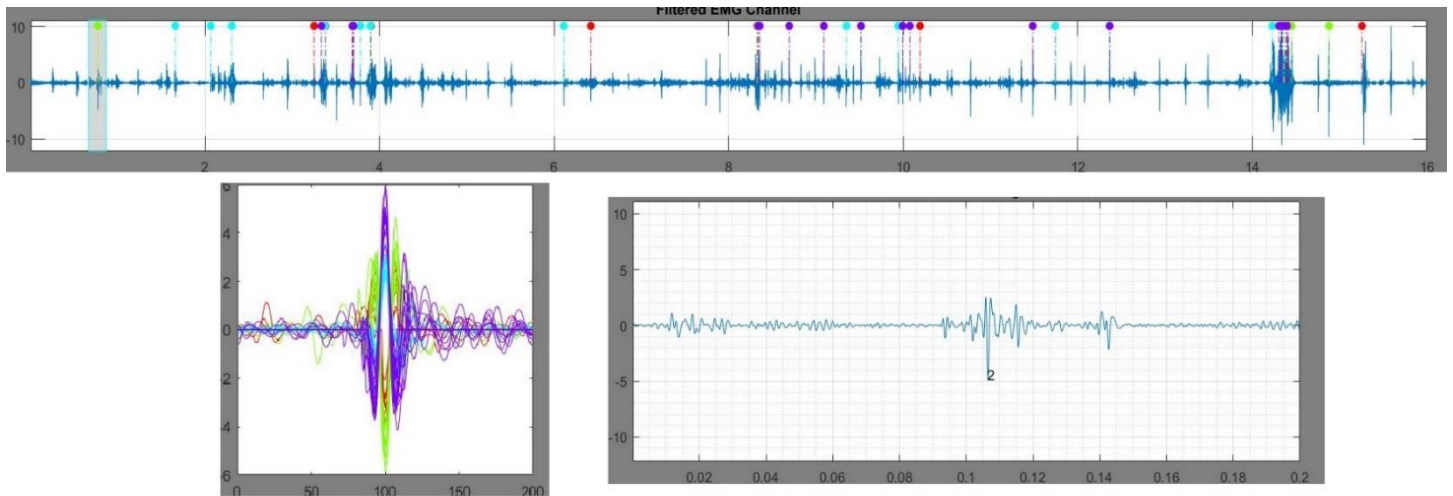
Se establece también una distancia mínima en la detección de picos, con la finalidad de que no se detecten dos picos de la misma activación como dos activaciones diferentes. De esta forma también podemos aislar las ventanas en las que se producen activaciones musculares alrededor de estos picos para su posterior análisis.

### 4.3. DESCOMPOSICIÓN


En primer lugar empleamos el algoritmo interactivo de Matlab EMGLAB [31]. Introducimos la señal previamente filtrada para eliminar la interferencia de 50 Hz como hemos explicado anteriormente. A continuación se procede a la descomposición de la señal, pero los resultados son negativos ya que se obtienen potenciales de acción muy difusos e inespecíficos. Esto sucede porque un solo canal no es suficiente para este algoritmo y no consigue descomponer la señal de forma eficiente. Se intentan ajustar los parámetros de descomposición como las ventanas de toma de datos, la longitud de la señal EMG o el filtrado consecutivo de la señal, pero en ningún caso se obtiene un

resultado satisfactorio. En capítulos posteriores se discutirán las diferentes limitaciones encontradas.


Así, emplearemos el otro algoritmo de Matlab [33] mencionado anteriormente. Antes de proceder a la descomposición de las señales, procedemos del mismo modo a filtrar la señal Raw para eliminar la interferencia de 50 Hz. Introducimos esta señal y ajustamos los parámetros de descomposición hasta obtener el mayor número posible de potenciales de acción identificados. Los resultados obtenidos son los siguientes para las señales del dedo anular, corazón y combinados respectivamente:



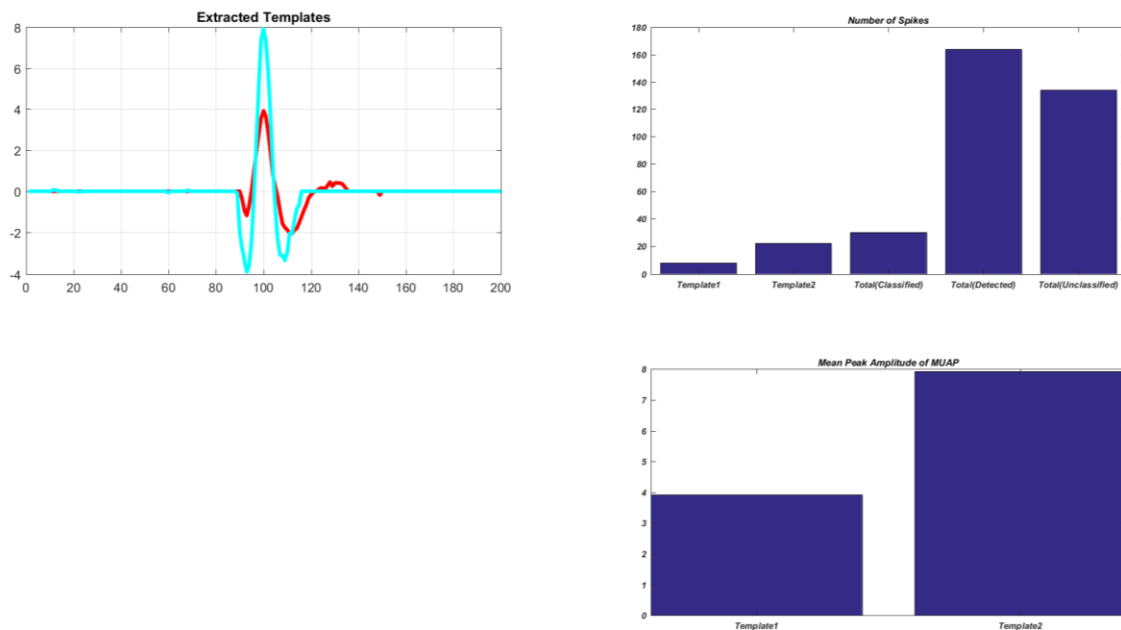
**Figura 17.** Descomposición de la señal Raw del dedo anular.



**Figura 18.** Descomposición de la señal Raw del dedo corazón.



**Figura 19.** Descomposición de la señal Raw de ambos dedos combinados.



**Figura 20.** Resultados de la descomposición para el dedo corazón.

A pesar de la mejora considerable respecto al otro algoritmo, este sigue sin ser suficientemente preciso para una correcta descomposición de las señales, ya que como podemos ver, sólo clasifica el 17% de los potenciales de acción identificados para el dedo corazón. Las limitaciones encontradas en este aspecto también serán tratadas en siguientes capítulos.


Una vez hemos visto y comprobado las limitaciones de los métodos directos de extracción de estrategias neuronales a partir de señales EMG superficiales y ante la

falta de una bibliografía consistente respecto a la descomposición de señales EMG superficiales de un solo canal, nos vemos obligados a pasar a los métodos indirectos.

#### 4.4. AMPLITUD

Para analizar la amplitud es útil trabajar con la señal de EMG rectificada. En este caso, aprovechando su uso para la obtención de la envolvente de la señal, empleamos el RMS para extraer su amplitud. También es útil usar este método porque ofrece una buena segmentación de la señal EMG gracias a la ventana móvil y solapamiento que podemos ajustar. Empleamos una ventana de 50 ms y un solapamiento de 5 muestras tal y como establece la bibliografía.


En primer lugar se ha obtenido la amplitud de las señales de los dedos anular y corazón mediante RMS. Después, se ha determinado un umbral de actuación para la detección del movimiento siguiendo los pasos que especificamos en capítulos anteriores. A continuación, guardamos en una variable el valor de la amplitud para los picos detectados. Una vez tenemos esta variable con los valores RMS que superan el umbral (cinco veces el valor medio del ruido de fondo de la señal) procedemos a plasmarlo en un diagrama para ver si podemos sacar una conclusión directa:



**Figura 21.** Comparativa de amplitudes de los dedos corazón y anular obtenidas mediante RMS. Eje Y en unidades arbitrarias.


Teniendo en cuenta que los datos se han obtenido de electrodos situados sobre el flexor digitorum superficialis (FDS), el resultado de la amplitud concuerda con algunos estudios en los que se analiza la señal EMG obtenida para electrodos situados en el FDS [35], [36].

En la siguiente figura se puede observar la respuesta del EMG para el movimiento de cada dedo, siendo 3f el dedo corazón y 4f el anular [35].



**Figura 22.** Amplitud de la señal EMG de cada dedo sobre el flexor digitorum superficialis. Donde 3f es el dedo corazón y 4f el anular.

En la siguiente figura se puede observar la amplitud RMS de cada dedo para varios tipos de movimiento [31]:




**Figura 23.** Amplitud RMS de cada dedo para varios movimientos.

Como podemos observar, la amplitud obtenida en nuestra muestra del dedo anular es claramente superior a la del dedo corazón, pero hay que tener en cuenta que hay valores

de amplitud que se encuentran en el límite y no estaría clara su clasificación posterior. Por ello debemos seguir extrayendo características de la señal EMG para lograr una clasificación fiable.

Podemos ver esa cercanía entre algunas de las amplitudes de cada dedo mirando la siguiente figura:



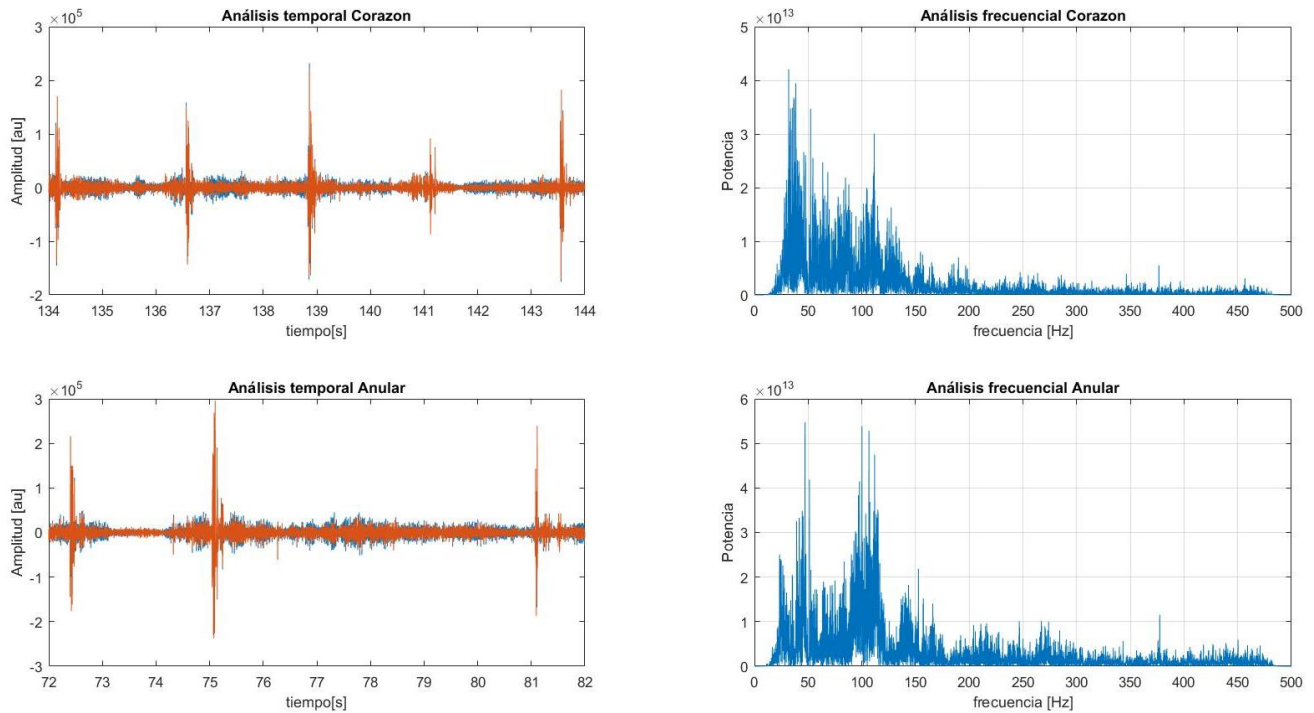
**Figura 24.** Activación detectada para cada dedo.

A la hora de calcular la conducción neuronal a partir de la amplitud como sugiere Farina et al. [37], nos encontramos con que, al no haber logrado una correcta descomposición, desconocemos los potenciales de acción de unidad motora de forma individual, por lo que nos es imposible inferir este tipo de información. Los resultados serán discutidos y analizados en capítulos posteriores.

## 4.5. FRECUENCIA

Para pasar la señal del dominio del tiempo al dominio de la frecuencia se emplea la transformada rápida de Fourier (FFT). En primer lugar observamos las frecuencias de la señal Raw, que como hemos comentado, se encuentra filtrada con un filtro paso banda de 20 – 400 Hz. Adicionalmente se filtra para eliminar la interferencia de 50 Hz.

A continuación se puede ver la respuesta frecuencial para las señales Raw del dedo corazón y anular durante un periodo de 10 segundos:



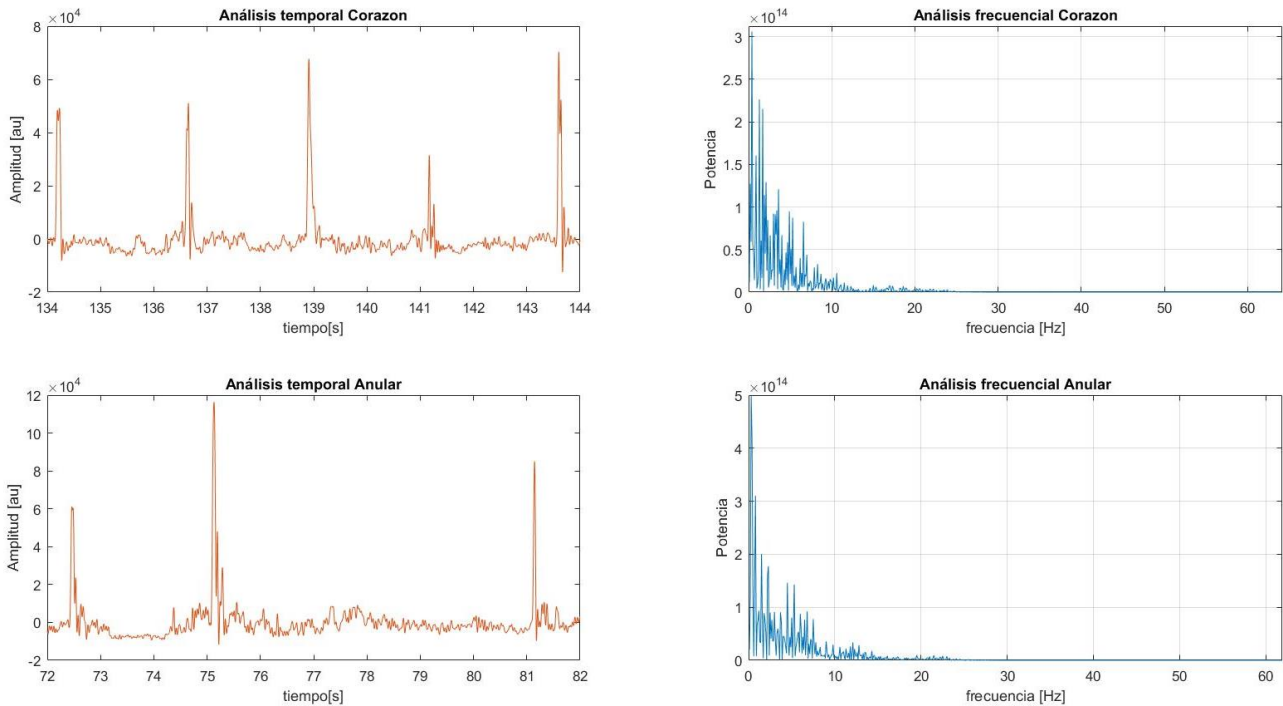
**Figura 25.** Análisis frecuencial de la señal Raw del dedo corazón y anular para una muestra de 10 segundos. La señal superpuesta se obtiene tras el filtrado con el filtro Butterworth a 50 Hz.

Se pueden observar en ambos dedos picos en frecuencias en torno a 25 – 40 Hz y en múltiplos de estas, como predijimos en anteriores capítulos.

También podemos observar que en el dedo corazón las frecuencias que más aparecen se concentran en torno a 40 Hz. Por otro lado, en el dedo anular éstas se acumulan en torno a 100 Hz. Esta información nos puede ser útil para posteriores análisis.



Dado que la señal ya se encuentra filtrada con el filtro paso banda, es posible que se estén perdiendo datos relevantes de frecuencias por debajo de 20 Hz. Para que esto no suceda, empleamos la señal Filtered (señal rectificada y filtrada con un filtro paso bajo de 20 Hz):




**Figura 26.** Análisis frecuencial de la señal Rectified (rectificada y filtrada) del dedo corazón y anular para un período de 10 segundos.

Lo primero que llama la atención al mirar las frecuencias es el pico entre 0 – 4 Hz. Este pico es debido al offset de corriente continua que provoca la salida de los amplificadores. El resto de bajas frecuencias que aparecen sí que son características del ratio de disparo de las unidades motoras y pertenecen al espectro de la señal EMG.

Debido al carácter no-estacionario de la señal, sería conveniente analizar la frecuencia en cada periodo de la señal mediante la STFT como hemos comentado anteriormente. De esta forma obtendremos información relevante de las frecuencias medias en cada periodo. A continuación se puede ver la STFT para una ventana de 500 ms en la que se aprecia la activación del dedo corazón:





**Figura 27.** STFT del dedo corazón para una ventana de 500 ms.

Por último, teniendo en cuenta todos los procesos anteriores, obtenemos los siguientes descriptores frecuenciales de las señales EMG para cada dedo:


**Tabla 2.** Descriptores frecuenciales inferidos.

Parámetro	Anular	Corazón
Frecuencia Media (MDF)	130 – 135 Hz	100 – 105 Hz
Frecuencia Principal (MNF)	170 – 180 Hz	145 – 155 Hz
Ratio medio de disparo	45 Hz	27 Hz

## 4.6. CORRELACIÓN CRUZADA

A continuación, procedemos a emplear el análisis de correlación cruzada para encontrar similitudes entre las señales de activación de diferentes dedos. Comparamos las señales Filtered (señal rectificada y filtrada con filtro paso bajo de 20 Hz) de los dedos corazón y anular con la señal de ambos dedos combinados, para ver en ella cuál de las dos señales se asemeja más. Se emplean ventanas de 2 segundos de duración como sugirieren Winter et al. [11] y se normalizarán los ejes verticales. Se centra esa ventana aislando una activación de cada dedo y dos activaciones en el combinado.

En la siguiente figura, los tres primeros gráficos muestran la activación de cada dedo y la señal combinada en la ventana de 2 segundos seleccionada. Los dos últimos gráficos muestran los coeficientes de correlación cruzada entre el dedo corazón y combinado y entre el dedo anular y combinado. El eje x de estas dos últimas muestra el retraso entre las señales al ser comparadas, como se ha explicado anteriormente.



**Figura 28.** Correlación cruzada para una activación de cada dedo respecto al combinado.

Los picos pronunciados en el análisis de correlación cruzada indican una alta coincidencia entre las señales. Podemos observar un pico pronunciado en la correlación entre el dedo corazón y la segunda activación del combinado (círculo verde), lo que nos hace pensar en que esa activación la ha producido ese dedo. Del mismo modo sucede con el dedo anular y la primera activación del combinado (círculo rojo).

Mediante la correlación cruzada también hemos analizado el ruido de fondo en todas las señales para cerciorarnos de que era muy similar en todas ellas. Hemos obtenido coeficientes de correlación muy elevados para todas ellas comparándolas con la señal de reposo, por lo cual se confirma que el ruido de fondo es semejante.

Mediante la correlación cruzada podemos distinguir la señal de actuación de un modo visual. Esta aplicación no será efectiva para la finalidad de este trabajo, ya que se pretende estimar la señal de actuación de forma rápida y autónoma para su posterior aplicación al tratamiento de señales en tiempo real.


## 4.7. CLASIFICACIÓN

Para conseguir diferenciar el movimiento de cada dedo, empleamos métodos de clasificación supervisados. En concreto se usan clasificadores basados en máquinas de vectores de soporte (Support vector machine, SVP). Estos métodos utilizan vectores de información conocida (en nuestro caso, las señales de activación del dedo anular, del dedo corazón y de reposo) para entrenar un clasificador. Después, se emplea este clasificador para clasificar información nueva (en nuestro caso, la señal de los dedos combinados).

Son muchos los clasificadores que se usan a este respecto. Nos centraremos en aquellos que permitan la mejor clasificación a partir de parámetros ya calculados, como amplitud RMS y frecuencias medias y principales. Cui et al. [38] comparan varios métodos de clasificación basándose en RMS y SVP. Se obtienen resultados de entre el 85% y el 95% de precisión en las clasificaciones para una muestra de EMG superficial tomada con cuatro canales.

En nuestro caso, el proceso seguido es el siguiente: a partir de la señal RMS (rectificada, filtrada y aplicando RMS con una ventana de 50 ms) creamos un vector con datos correspondientes a activaciones musculares. Después, se crea una tabla de datos en Matlab. En cada columna incluimos una característica de las obtenidas anteriormente que funciona como 'predictores'. Por último, en la última columna incluimos la respuesta, que es una etiqueta para clasificar cada uno de estos datos conocidos ('A' para anular, 'C' para corazón y 'R' para reposo). A continuación, Se usa la *Classification Learner App* de Matlab para entrenar un clasificador. Se entrenan clasificadores basados en SVP con los datos anteriores ya conocidos y se escoge el de mayor precisión.

A continuación se puede ver la forma en la que se entrenan los clasificadores empleando esta herramienta de Matlab:




**Figura 29.** Entrenamiento de clasificadores con Clasification Learner App, Matlab.

En la siguiente tabla se pueden observar las precisiones obtenidas para los diferentes clasificadores y técnicas que se han probado:

**Tabla 3.** Precisión obtenida según el método de clasificación.

Método de clasificación	Precisión [%]		
	Anular	Corazón	Reposo
RMS+STFT+SVM	57	82	99
STFT+SVM	32	25	75
RMS+Decision Tree	45	62	94
RMS+Análisis Lineal	45	65	92

A la vista de los resultados obtenidos, elegimos la técnica RMS con STFT junto con el clasificador *Fine Gaussian SVM*, ya que nos proporciona una precisión del 79,3%. Obtenemos la siguiente matriz de confusión:



**Figura 30.** Matriz de confusión del clasificador Fine Gaussian SVM.

Como podemos observar, obtenemos clasificaciones muy buenas tanto para el reposo como para el dedo corazón. En cambio, para el dedo anular no obtenemos la precisión deseada ya que un 38% de los datos analizados serán falsos positivos y los considerará activaciones del dedo corazón.

Siguiendo las indicaciones de Oskoei y Hu [39], para entrenar al clasificador hemos tenido en cuenta los siguientes valores de amplitud: RMS, *mean absolute value* (MAV) y *moving average* (MA). Por otro lado, se han tenido en cuenta los valores de frecuencia que nos proporciona la STFT. De esta forma hemos incluido valores tanto temporales como tiempo-frecuenciales para obtener la máxima precisión en la clasificación.

En la siguiente figura se pueden ver las características empleadas para el entrenamiento del clasificador:

	1	2	3	4	5
	ACR_MA	ACR_RMS	ACR_MAV	ACR_WT	ACR_L
1	8.2399e+03	5.0634e+03	1.2010e+04	9.6024	A
2	8.1673e+03	1.4155e+04	1.2561e+04	9.6224	A
3	8.6148e+03	4.2360e+03	1.1509e+04	9.5752	A
4	9.2274e+03	4.5971e+03	1.1506e+04	9.5753	A
5	9.2226e+03	4.0575e+03	1.1300e+04	9.5840	A
6	9.1703e+03	1.6455e+04	1.1489e+04	9.5695	A
7	8.9500e+03	2.9413e+04	1.0187e+04	9.4547	A
8	8.7880e+03	2.4856e+04	7.5826e+03	9.1698	A
9	8.7474e+03	4.6218e+03	5.3950e+03	8.7486	A
10	1.0222e+04	1.2645e+04	5.1417e+03	8.6988	A
11	1.1230e+04	1.0571e+04	5.0089e+03	8.6274	A
12	1.1632e+04	3.6367e+03	4.8596e+03	8.5448	A
13	1.2204e+04	4.2044e+03	4.5570e+03	8.4842	A
14	1.3709e+04	2.5415e+03	5.0130e+03	8.5400	A
15	1.4395e+04	5.9454e+03	6.0840e+03	8.8774	A
16	1.5482e+04	3.4323e+03	5.9000e+03	8.9372	A
17	1.7637e+04	3.3725e+03	6.1918e+03	9.0244	A

**Figura 31.** Características para entrenar al clasificador.

Una vez hemos entrenado el clasificador más adecuado, lo aplicamos a la señal de los dedos combinados para conseguir diferenciar la señal de actuación de un dedo u otro.

## 5. DISCUSIÓN

### *Descomposición*

Respecto a la descomposición de las señales, a la vista de los resultados obtenidos para ambos algoritmos de descomposición, y tras cotejarlos con los criterios de precisión de identificación de unidades motoras [18], podemos afirmar que ninguno de los dos algoritmos logra extraer información de forma satisfactoria. Este resultado encaja con estudios que se han hecho respecto al empleo de un solo canal EMG para descomposición de señales, donde se expone que de esta forma, sólo se logra detectar el 3,5% de los potenciales de acción de unidad motora frente al 90,4% que se consigue con una matriz de 81 electrodos con un filtro Laplaciano [40].

Del mismo modo, ha sido imposible obtener información relativa a la conducción neuronal, ya que al no lograr una descomposición correcta, no se ha podido contabilizar el número de descargas de potenciales de acción por cada unidad motora (de este modo se calcula la conducción neuronal [37]).

Empleando electrodos intramusculares o una matriz de electrodos superficiales, se podría obtener tanto la conducción neuronal como los ratios de disparo de las unidades motoras [41]. Nos vemos así limitados, ya que la muestra ha sido tomada con electrodos superficiales en un solo canal.

### *Amplitud*

Pasando al análisis de la amplitud, hemos logrado obtener información relevante sobre la activación muscular estableciendo un nivel de umbral a la señal RMS del EMG. También hemos podido comparar los valores de amplitud entre las distintas señales de activación de un dedo u otro. Nos hemos visto limitados a la hora de inferir información como el ratio de disparo de las unidades motoras (útil para ver estrategias de reclutamiento) o estimar el número de unidades motoras activas. Para conseguir esa información a partir del EMG superficial hubiera sido necesaria una correcta descomposición de la señal en sus potenciales de acción de unidad motora [21]. Otros estudios han logrado calcular cuantitativamente todos estos parámetros empleando electrodos intramusculares junto con técnicas avanzadas de descomposición [42]. Se vuelve a hacer así referencia al empleo de, o bien electrodos más selectivos (intramusculares), o bien electrodos superficiales que utilicen un gran número tanto de

electrodos como de canales (matrices de electrodos) para conseguir extraer eficientemente características neuronales a partir de señales EMG.

### ***Frecuencia***

Como hemos comentado en el capítulo correspondiente, en los últimos años el empleo de análisis frecuenciales para inferir características neuronales ha ido en descenso ya que se ha probado que estos análisis no son precisos bajo algunas circunstancias [6], [9]. Por lo tanto, no ha sido posible inferir información como el tipo de unidades motoras o las estrategias de reclutamiento de las mismas. En cambio, en el presente trabajo, el empleo del análisis frecuencial nos ha resultado muy útil para los siguientes propósitos:

Por una parte, hemos podido observar el espectro de la señal para corregir con filtros las diferentes distorsiones que se han apreciado. Por otro lado, hemos podido extraer información en el dominio tiempo-frecuencia que ha sido de vital importancia para el empleo de un clasificador eficaz, ya que el análisis de la amplitud de la señal no nos ofrecía toda la información necesaria para una clasificación idónea.

### ***Correlación cruzada***

Con el empleo de coeficientes de correlación cruzada hemos podido observar las similitudes entre las señales de una forma visual. En primer lugar, hemos verificado que el ruido de fondo sea similar en todas las muestras comparándolas con la señal de reposo. En segundo lugar, hemos comprobado que podríamos determinar la actuación de un dedo u otro, pero de una forma manual y tediosa, por lo que, si bien no emplearemos este método para tal efecto, podría servirnos para obtener información adicional en algún punto conflictivo de la muestra.

### ***Clasificación***

La elección de un clasificador eficaz para conseguir diferenciar el movimiento de un dedo u otro es vital para obtener unos porcentajes de precisión adecuados. Se ha seguido la bibliografía partiendo de datos que se habían obtenido para inferir características neuronales y se han empleado para el entrenamiento de un clasificador basado en SVM. Los porcentajes de clasificación obtenidos han sido los óptimos teniendo en cuenta las limitaciones que hemos ido comentando a lo largo del trabajo.



Si pretendiéramos usar esta clasificación para modelos en tiempo real, sería necesario realizar modificaciones, ya que se ha demostrado que el tratamiento “off-line” obtiene siempre mejores resultados [18]. Debería utilizarse otro tipo de clasificador que no emplee datos para entrenarse (no-supervisado) o bien un clasificador supervisado que entrene con los mismos datos que recibe para su clasificación de forma dinámica.

### ***Otros datos a tener en cuenta***

El presente trabajo no ha tenido como objetivo calcular la velocidad de conducción, ya que como hemos mencionado anteriormente, harían falta dos canales como mínimo para poder medir el retraso entre las señales. Tampoco se ha podido inferir esta información del análisis frecuencial ya que se ha probado que no existe relación entre la velocidad de conducción y el análisis frecuencial [6]. También ha sido probado que no es posible determinar el tipo de fibras musculares a partir de la velocidad de conducción [18].

## 6. CONCLUSIONES

Con este estudio hemos podido probar técnicas alternativas a las que emplean métodos de identificación de patrones de movimiento en señales EMG. Se pretendían extraer estrategias neuronales a partir de señales EMG superficiales, así como conseguir diferenciar la señal de actuación entre dos dedos. Durante el procesado de la señal, hemos podido comprobar las limitaciones de emplear señales de un solo canal para poder cumplir el objetivo del trabajo. Otros estudios confirman esta limitación, ya que existen demasiados factores desconocidos y muy pocos factores para desenredar la información contenida en una señal de este tipo [8].

Si bien se ha conseguido obtener información coherente respecto a la amplitud y el espectro, esta información no ha sido suficiente para determinar características neuronales por todos los motivos expresados en el apartado anterior, pero sí que nos han servido para identificar el movimiento del dedo anular y corazón con una precisión correcta, en una muestra de ambos movimientos intercalados a partir de dos muestras con movimientos independientes.

De esta forma, el trabajo nos ha permitido hacer un repaso por las técnicas empleadas para la detección de estrategias neuronales en señales EMG. Se ha hecho una revisión de numerosos estudios (muchos de ellos muy actuales) y hemos podido comprobar de primera mano las limitaciones que se presentan en función del material y las muestras que se empleen.

No hay que olvidar que aunque con la tecnología y técnicas disponibles a día de hoy se puede obtener información y conclusiones más precisas, hay que tener en cuenta que toda esta información se ha podido extraer de una forma completamente no-invasiva y con un bajo coste (se incluye un breve presupuesto en los anexos). Por lo tanto, sería posible aplicar estas técnicas en cualquier lugar y emplear esta información para otros fines como pueden ser el control de un exoesqueleto de miembro superior o para simulaciones en ordenador. Además, si tuviéramos en cuenta algunos de los aspectos comentados anteriormente, podríamos seguir perfeccionando el sistema y obtener cada vez información más útil y precisa.

Por todo lo mencionado anteriormente, cabe destacar que cada vez más estudios sugieren el empleo de un mayor número de electrodos. Las matrices de electrodos ofrecen la mejor solución a día de hoy para la extracción de todo tipo de información empleando técnicas no-invasivas. De esta forma podríamos también descomponer la

señal EMG superficial en sus potenciales de acción de una forma muy precisa y así extraer información de forma directa sobre la conducción neuronal.

Durante la realización de este trabajo, hemos podido obtener información relativa al procesamiento de señal EMG superficial de los dedos corazón y anular de la mano. Aunque hayamos evidenciado las limitaciones de algunas de las técnicas de este estudio, cabe destacar que el procesamiento de señales EMG superficiales se tiene que seguir desarrollando en el ámbito de la biomedicina, ya que generará numerosos avances para el control de exosqueletos y rehabilitación, propiciando un aumento en la calidad de vida de los pacientes con limitaciones funcionales tanto de miembro superior como inferior.

## 7. REFERENCIAS

- [1] S. Micera, J. Carpaneto, y S. Raspopovic, "Control of hand prosthesis using peripheral information," *Biomed. Eng. IEEE Rev.*, vol. 3, pp. 48–68, 2010.
- [2] "'Peripheral nervous system', Austin Community College, 2014, [en línea]. Disponible en: <http://www.austincc.edu/rfofi/NursingRvw/PhysText/PNSEfferent.html>." .
- [3] C. J. De Luca y W. J. Forrest, "Some properties of motor unit action potential trains recorded during constant force isometric contractions in man," *Kybernetik*, vol. 12, no. 3, pp. 160–168, Mar. 1973.
- [4] J. V. Basmajian y C. J. De Luca, *Muscles alive: their functions revealed by electromyography*. Williams & Wilkins, 1985.
- [5] A. Merlo y I. Campanini, *Technical Aspects of Surface Electromyography for Clinicians*, vol. 3. 2010.
- [6] D. Farina, R. Merletti, y R. M. Enoka, "The extraction of neural strategies from the surface EMG: an update," *J. Appl. Physiol.*, vol. 117, no. 11, pp. 1215–1230, 2014.
- [7] M. Asghari Oskoei y H. Hu, "Myoelectric control systems—A survey," *Biomed. Signal Process. Control*, vol. 2, no. 4, pp. 275–294, Oct. 2007.
- [8] R. Merletti, A. Rainoldi, y D. Farina, "Surface electromyography for noninvasive characterization of muscle.," *Exerc. Sport Sci. Rev.*, vol. 29, no. 1, pp. 20–25, 2001.
- [9] D. Farina, R. Merletti, y R. M. Enoka, "The extraction of neural strategies from the surface EMG.," *J. Appl. Physiol.*, vol. 96, no. 4, pp. 1486–1495, Apr. 2004.
- [10] D. Farina, R. Merletti, B. Indino, N. M. y P. M., "Cross-talk between knee extensor muscles. Experimental and model results," *Muscle Nerve* 26, pp. 681–695, 2002.
- [11] D. A. Winter, A. J. Fuglevand, y S. E. Archer, "Crosstalk in surface electromyography: Theoretical and practical estimates," *J. Electromyogr. Kinesiol.*, vol. 4, no. 1, pp. 15–26, 1994.
- [12] R. Merletti, A. Botter, A. Troiano, E. Merlo, y M. A. Minetto, "Technology and instrumentation for detection and conditioning of the surface electromyographic signal: State of the art," *Clin. Biomech.*, vol. 24, no. 2, pp. 122–134, Feb. 2009.

- [13] C. J. De Luca, "Surface electromyography: Detection and recording," *DeSys Inc.*, vol. 10, no. 2, pp. 1–10, 2002.
- [14] K. G. Keenan, D. Farina, K. S. Maluf, R. Merletti, y R. M. Enoka, "Influence of amplitude cancellation on the simulated surface electromyogram.," *J. Appl. Physiol.*, vol. 98, no. 1, pp. 120–131, Jan. 2005.
- [15] D. Farina, C. Cescon, F. Negro, y R. M. Enoka, "Amplitude Cancellation of Motor-Unit Action Potentials in the Surface Electromyogram Can Be Estimated With Spike-Triggered Averaging," *J. Neurophysiol.*, vol. 100, no. 1, pp. 431–440, Jul. 2008.
- [16] C. De Luca, *Physiology and Mathematics of Myoelectric Signals*, vol. 26. 1979.
- [17] D. Stashuk, "EMG signal decomposition: how can it be accomplished and used?," *J. Electromyogr. Kinesiol.*, vol. 11, no. 3, pp. 151–173, Jun. 2001.
- [18] R. Merletti y D. Farina, *Surface Electromyography: Physiology, Engineering and Applications*. 2016.
- [19] L. J. Myers *et al.*, "Rectification and non-linear pre-processing of EMG signals for cortico-muscular analysis.," *J. Neurosci. Methods*, vol. 124, no. 2, pp. 157–165, Apr. 2003.
- [20] P. Konrad, "The abc of emg," *A Pract. Introd. to Kinesiol. Electromyogr.*, vol. 1, pp. 30–35, 2005.
- [21] M. B. I. Raez, M. S. Hussain, F. Mohd-Yasin, M. Reaz, M. S. Hussain, y F. Mohd-Yasin, "Techniques of EMG signal analysis: detection, processing, classification and applications.," *Biol. Proced. Online*, vol. 8, no. 1, pp. 11–35, 2006.
- [22] P. Bonato, T. D'Alessio, y M. Knaflitz, "A statistical method for the measurement of muscle activation intervals from surface myoelectric signal during gait.," *IEEE Trans. Biomed. Eng.*, vol. 45, no. 3, pp. 287–299, Mar. 1998.
- [23] M. Zecca, S. Micera, M. C. Carrozza, y P. Dario, "Control of multifunctional prosthetic hands by processing the electromyographic signal.," *Crit. Rev. Biomed. Eng.*, vol. 30, no. 4–6, pp. 459–485, 2002.
- [24] K. T. Özgünen, U. Çelik, y S. S. Kurdak, "Determination of an Optimal Threshold Value for Muscle Activity Detection in EMG Analysis," *J. Sports Sci. Med.*, vol. 9, no. 4, pp. 620–628, Dec. 2010.
- [25] D. Renz, "'Short-time FFT, Multi-taper analysis & Filtering in SPM12', Translational

- neuromodeling, 2015, [en línea]. Disponible en: [http://www.translationalneuromodeling.org/uploads/TNU\\_SpringSeminar2015\\_EEG-Signal-Processing\\_Week05\\_DanielRenz\\_Short\\_timeFFT\\_Multi\\_](http://www.translationalneuromodeling.org/uploads/TNU_SpringSeminar2015_EEG-Signal-Processing_Week05_DanielRenz_Short_timeFFT_Multi_) 2015. .
- [26] R. Bose, K. Samanta, y S. Chatterjee, *Cross-correlation based feature extraction from EMG signals for classification of neuro-muscular diseases*. 2016.
  - [27] M. M. Lowery, N. S. Stoykov, y T. A. Kuiken, "A simulation study to examine the use of cross-correlation as an estimate of surface EMG cross talk.," *J. Appl. Physiol.*, vol. 94, no. 4, pp. 1324–1334, Apr. 2003.
  - [28] T. A. L. Wren, K. P. Do, S. A. Rethlefsen, y B. Healy, "Cross-correlation as a method for comparing dynamic electromyography signals during gait.," *J. Biomech.*, vol. 39, no. 14, pp. 2714–2718, 2006.
  - [29] N. Nazmi, M. A. Abdul Rahman, S.-I. Yamamoto, S. A. Ahmad, H. Zamzuri, y S. A. Mazlan, "A Review of Classification Techniques of EMG Signals during Isotonic and Isometric Contractions," *Sensors (Basel)*., vol. 16, no. 8, p. 1304, Aug. 2016.
  - [30] A. F. Caballero, D. S. Copaci, Á. V. Peciña, D. B. Rojas, y L. M. Lorente, "Sistema Avanzado de Protipado Rápido para Control en la Educación en Ingeniería para grupos Multidisciplinares," *Rev. Iberoam. Automática e Informática Ind. RIAI*, vol. 13, no. 3, pp. 350–362, Jul. 2016.
  - [31] M. H. McGill KC, Lateva ZC, "EMGLAB: an interactive EMG decomposition program." p. J Neurosci Methods 149(2):121-133, 2005.
  - [32] K. C. McGill, Z. C. Lateva, y M. E. Johanson, "Validation of a computer-aided EMG decomposition method," in *Engineering in Medicine and Biology Society, 2004. IEMBS'04. 26th Annual International Conference of the IEEE*, 2004, vol. 2, pp. 4744–4747.
  - [33] H. Sedghamiz y D. Santonocito, *Unsupervised Detection and Classification of Motor Unit Action Potentials in Intramuscular Electromyography Signals*. 2015.
  - [34] S. Karlsson, J. Yu, y M. Akay, "Time-frequency analysis of myoelectric signals during dynamic contractions: a comparative study," *IEEE Trans. Biomed. Eng.*, vol. 47, no. 2, pp. 228–238, 2000.
  - [35] M. H. Schieber, "Muscular production of individuated finger movements: the roles of extrinsic finger muscles.," *J. Neurosci.*, vol. 15, no. 1 Pt 1, pp. 284–297, Jan. 1995.

- [36] X. Hu, N. L. Suresh, C. Xue, y W. Z. Rymer, "Extracting extensor digitorum communis activation patterns using high-density surface electromyography.," *Front. Physiol.*, vol. 6, p. 279, 2015.
- [37] D. Farina, A. Holobar, R. Merletti, y R. M. Enoka, "Decoding the neural drive to muscles from the surface electromyogram.," *Clin. Neurophysiol.*, vol. 121, no. 10, pp. 1616–1623, Oct. 2010.
- [38] L. Cui, T. Aughey, M. Li, G. Xu, y G. T. Allison, "A comparative study on finger-movement classification based on surface-electromyography-peak parameters," *Int. J. Manag. Appl. Sci.*, pp. 34–38, 2017.
- [39] M. A. Oskoei y H. Hu, "Support vector machine-based classification scheme for myoelectric control applied to upper limb," *IEEE Trans. Biomed. Eng.*, vol. 55, no. 8, pp. 1956–1965, 2008.
- [40] D. Farina, F. Negro, M. Gazzoni, y R. M. Enoka, "Detecting the Unique Representation of Motor-Unit Action Potentials in the Surface Electromyogram," *J. Neurophysiol.*, vol. 100, no. 3, pp. 1223–1233, Sep. 2008.
- [41] C. J. De Luca y E. C. Hostage, "Relationship Between Firing Rate and Recruitment Threshold of Motoneurons in Voluntary Isometric Contractions," *J. Neurophysiol.*, vol. 104, no. 2, pp. 1034–1046, Aug. 2010.
- [42] K. N. Ryan, "A Quantitative EMG Assessment of Motor Unit Recruitment in Patients with Ulnar Neuropathy," 2013.

## ANEXOS

### A.1. PRESUPUESTO

Si bien existe tecnología mucho más avanzada para la toma de datos EMG a día de hoy, el siguiente estudio consigue con un bajo coste material unos resultados muy satisfactorios.

A continuación podemos ver el desglose del presupuesto de los materiales que serían necesarios para aplicar lo visto en el presente trabajo:

**Tabla 4.** Presupuesto.

<b>Materiales</b>	<b>Ud.</b>	<b>Precio unitario</b>	<b>Total</b>
Placa adquisición EMG	1	116,24 €	116,24 €
Electrodos Ag/AgCl	20	0,15 €	3,00 €
Cables	4	2,16 €	8,64 €
PC	1	600,00 €	600,00 €
Placa procesamiento (STM32F4)	1	22,75 €	22,75 €
<b>TOTAL MATERIALES</b>			<b>750,63 €</b>
<b>Software</b>			
Matlab (Licencia educativa)	1	500,00 €	500,00 €
Signal processing toolbox	1	35,00 €	35,00 €
Statistics and machine learning toolbox	1	35,00 €	35,00 €
<b>TOTAL SOFTWARE</b>			<b>570,00 €</b>
<b>TOTAL SISTEMA (IVA incluido)</b>			<b>1.320,63 €</b>

### A.2. TIEMPOS DE PROCESADO

Debido a la gran capacidad computacional que tenemos a día de hoy, el tiempo de computación no juega un papel tan vital como hace unos años. Aun así, es útil tenerlo en cuenta por si en el futuro se pretenden emplear estas técnicas para procesado en tiempo real.

La siguiente tabla muestra los tiempos de procesado obtenidos para las siguientes tareas en nuestro trabajo (calculados sobre una muestra de 25 segundos):



Tarea	t [s]
Rectificado	0,095
Filtrado	0,122
Detección activación	0,321
Descomposición	1,201
Correlación cruzada	0,952
RMS	0,099
FFT	0,235
STFT	0,228
Clasificación	0,952
<b>TOTAL</b>	<b>4,205</b>

### A.3. CÓDIGO MATLAB

Algunos de los métodos aplicados en el trabajo implementados en Matlab pueden verse a continuación:

#### *Detección de activaciones musculares*

```
clear all;
load ('Corazon.mat');
X1=raw.signals.values(20000:99990,:);
X=filtered.signals.values(20000:99990,:);
Y=rms(X, 50, 5, 1); %Rms ventana 50, overlap 5
Y2=Y(:,527:638);%Ruido de fondo
M=mean(Y2)*5; %media del ruido *5
x1=0;
x2=length(Y);
subplot(2,1,1);
plot(X1);
title('Señal RAW dedo corazón');
xlabel('T [ms]');
ylabel('uV');
subplot(2,1,2);
plot(Y);
hold on;
plot([x1, x2], [M, M]);
legend('EMG', 'Umbral de detección');
xlabel('muestras');
title('Rectificado, filtrado y suavizado');
hold on;
[Picos,Activacion] =
findpeaks(Y, 'MinPeakHeight',M, 'MinPeakDistance',10);
hold on;
plot(Activacion,Y(Activacion), 'rv', 'MarkerFaceColor', 'b');
```

```

Picos;
M2=mean(Picos);
%-----
load ('Anular.mat');
X1a=raw.signals.values(20000:100000,:);
Xa=filtered.signals.values(20000:100000,:);
Ya=rms(Xa, 50, 5, 1); %rms ventana 50, overlap 5
Y2a=Ya(:,1236:1346);%Ruido
Ma=mean(Y2a)*5; %media del ruido * 5
x1a=0;
x2a=length(Ya);
figure;
subplot(2,1,1);
plot(X1a);
title('Señal RAW dedo anular');
subplot(2,1,2);
plot(Ya);
hold on;
plot([x1a, x2a], [Ma, Ma]);
legend('EMG rectificado y filtrado', 'Umbral de detección');
title('Señal RMS (ventana de 50 muestras)');
hold on;
[Picosa,Activaciona] =
findpeaks(Ya, 'MinPeakHeight',Ma, 'MinPeakDistance',10);
hold on;
plot(Activaciona,Ya(Activaciona), 'rv', 'MarkerFaceColor', 'b');
Picos;M2a=mean(Picosa);

```

### **Cálculo de la STFT**

```

clear all;
load('Corazon.mat')
Fs = 1000;
X1 = raw.signals.values(20000:40000,:);
X1=double(X1);
window = 40;
d = designfilt('bandstopiir','FilterOrder',2, ... %filtro para
eliminar
frecuencias 50Hz
'HalfPowerFrequency1',49,'HalfPowerFrequency2',51, ...
'DesignMethod','butter','SampleRate',1000);
x=X1;%filtfilt(d,X1);
[S,F,T,P] = spectrogram(x,window,window/2,window,Fs);
for nn = 1:size(P,2)
normcumsumpsd = cumsum(P(:,nn))./sum(P(:,nn));
Ind = find(normcumsumpsd <=0.5,1, 'last');

```

```

medianfreqs(nn) = F(Ind);
end
mediaCo=mean(medianfreqs);
subplot(2,1,1);
plot(x);
title('Raw dedo Corazon');
subplot(2,1,2);
plot(T,medianfreqs);
title('STFT');
xlabel('T (s)');
ylabel('Frecuencia media(Hz)');
%%-----
load('Anular.mat')
X2 = raw.signals.values(20000:40000,:);
X2=double(X2);
x22=filtfilt(d,X2);
[S2,F2,T2,P2] = spectrogram(x22>window>window/2>window,Fs);
for nn2 = 1:size(P2,2)
normcumsumpsd2 = cumsum(P2(:,nn2))./sum(P2(:,nn2));
Ind2 = find(normcumsumpsd2 <=0.5,1,'last');
medianfreqs2(nn2) = F2(Ind2);
end
mediaAn=mean(medianfreqs2);
figure;
subplot(2,1,1);
plot(x22);
title('Anular');
subplot(2,1,2);
plot(T2,medianfreqs2);
xlabel('Time (seconds)');
ylabel('Median Frequency (Hz)');

```

### ***Cálculo coeficientes de correlación cruzada***

```

clear all;
load('Corazon.mat');
Fs=1000;
figure;
time=raw.time(46010:47000,:);
voltage=raw.signals.values(46010:47000,:);
voltage=double(voltage);
d = designfilt('bandstopiir','FilterOrder',2, ... %filtro para
eliminar
frecuencias 50Hz
'HalfPowerFrequency1',49,'HalfPowerFrequency2',51, ...
'DesignMethod','butter','SampleRate',1000);

```

```

%fvtool(d);
filtrada=filtfilt(d,voltage);
subplot(6,1,1),
plot(time,filtrada);
title('Análisis temporal Corazon')
xlabel('time[sec]')
ylabel('voltage[V]')
Y = fft(filtrada);
N = length(Y);
Y(1) = [];
power = abs(Y(1:N/2)).^2;
nyquist = 1/(2*0.001);
freq = (1:N/2)/(N/2)*nyquist;
power=power/max(abs(power));
subplot(6,1,2), plot(freq,power), grid on
xlabel('frecuencia [Hz]')
ylabel('Power')
title('Análisis frecuencial Corazon')
%-----
hold on;
load('Anular.mat');
time2=raw.time(40310:41310,:);
voltage2=raw.signals.values(40310:41310,:);
voltage2=double(voltage2);
filtrada2=filtfilt(d,voltage2);
subplot(6,1,3),
plot(time2,filtrada2);
title('Análisis temporal Anular')
xlabel('time[sec]')
ylabel('voltage[V]')
Y2 = fft(filtrada2);
N2 = length(Y2);
Y2(1) = [];
power2 = abs(Y2(1:N2/2)).^2;
nyquist2 = 1/(2*0.001);
freq2 = (1:N2/2)/(N2/2)*nyquist2;
power2=power2/max(abs(power2));
subplot(6,1,4), plot(freq2,power2), grid on
xlabel('frecuencia [Hz]')
ylabel('Power')
title('Análisis frecuencial Anular')
%-----
hold on;
load('Combinado.mat');
time3=raw.time(20010:end,:);
voltage3=raw.signals.values(20010:end,:);
voltage3=double(voltage3);
filtrada3=filtfilt(d,voltage3);

```

```

subplot(6,1,5)
plot(time3,filtrada3);
title('Análisis temporal Combinado')
xlabel('time[sec]')
ylabel('voltage[V]')
Y3 = fft(filtrada3);
N3 = length(Y3);
Y3(1) = [];
power3 = abs(Y3(1:N3/2)).^2;
nyquist3 = 1/(2*0.001);
freq3 = (1:N3/2)/(N3/2)*nyquist3;
power3=power3/max(abs(power3));
subplot(6,1,6), plot(freq3,power3), grid on
xlabel('frecuencia [Hz]')
ylabel('Power')
title('Análisis frecuencial Combinado')
%-----
figure;
[xCorr,lags] = xcorr(power3,power);
[xCorr2,lags2] = xcorr(power,power2);
subplot(2,1,1);
plot(lags,xCorr);
title('xC cor/comb');
subplot(2,1,2);
plot(lags2,xCorr2);
title('xC an/comb');
xCorr(495)
xCorr2(495)

```

### ***Cálculo de FFT para un movimiento de cada dedo***

```

clear all;
load('Corazon.mat');
figure;
time=raw.time(134000:135000,:);
voltage=raw.signals.values(134000:135000,:);
voltage=detrend(voltage); %para eliminar el DC offset
voltage=double(voltage);
d = designfilt('bandstopiir','FilterOrder',2, ... %filtro para
eliminar
frecuencias 50Hz
'HalfPowerFrequency1',49,'HalfPowerFrequency2',51, ...
'DesignMethod','butter','SampleRate',1000);
%fvtool(d);
filtrada=filtfilt(d,voltage);
subplot(6,1,1), plot(time,voltage)

```

```

hold on;
plot(time,filtrada);
title('Análisis temporal Corazon')
xlabel('time[sec]')
ylabel('voltage[V]')
Y = fft(filtrada);
N = length(Y);
Y(1) = [];
power = abs(Y(1:N/2)).^2;
nyquist = 1/(2*0.001);
freq = (1:N/2)/(N/2)*nyquist;
subplot(6,1,2), plot(freq,power), grid on
xlabel('frecuencia [Hz]')
ylabel('Power')
title('Análisis frecuencial Corazon')
%-----
hold on;
load('Anular.mat');
time2=raw.time(75000:76000,:);
voltage2=raw.signals.values(75000:76000,:);
voltage2=detrend(voltage2); %para eliminar el DC offset
voltage2=double(voltage2);
filtrada2=filtfilt(d,voltage2);
subplot(6,1,3), plot(time2,voltage2)
hold on;
plot(time2,filtrada2);
title('Análisis temporal Anular')
xlabel('time[sec]')
ylabel('voltage[V]')
Y2 = fft(filtrada2);
N2 = length(Y2);
Y2(1) = [];
power2 = abs(Y2(1:N2/2)).^2;
nyquist2 = 1/(2*0.001);
freq2 = (1:N2/2)/(N2/2)*nyquist2;
subplot(6,1,4), plot(freq2,power2), grid on
xlabel('frecuencia [Hz]') ylabel('Power')
title('Análisis frecuencial Anular')
%-----
hold on;
load('Combinado.mat');
time3=raw.time(79000:80000,:);
voltage3=raw.signals.values(79000:80000,:);
voltage3=detrend(voltage3); %para eliminar el DC offset
voltage3=double(voltage3);
filtrada3=filtfilt(d,voltage3);
subplot(6,1,5), plot(time3,voltage3)
hold on;

```

```

plot(time3,filtrada3);
title('Análisis temporal Combinado')
xlabel('time[sec]')
ylabel('voltage[V]')
Y3 = fft(filtrada3);
N3 = length(Y3);
Y3(1) = [];
power3 = abs(Y3(1:N3/2)).^2;
nyquist3 = 1/(2*0.001);
freq3 = (1:N3/2)/(N3/2)*nyquist3;
subplot(6,1,6), plot(freq3,power3), grid on
xlabel('frecuencia [Hz]')
ylabel('Power')
title('Análisis frecuencial Combinado')

```

### ***Preparación de los datos para entrenar al clasificador y posterior clasificación***

```

load('An_MA.mat')
load('R_MA.mat')
load('C_MA.mat')
load('R_RMS1.mat')
load('An_RMS1.mat')
load('C_RMS1.mat')
load('R_MAV.mat')
load('C_MAV.mat')
load('An_MAV.mat')
load('An_WT.mat')
load('C_WT.mat')
load('R_WT.mat')
A=An_MA(1:5003);
C=C_MA(1:5003);
R=R_MA(1:5003);
ACR_L=[];
A2=An_RMS1(1:5003);
C2=C_RMS1(1:5003);
R2=R_RMS1(1:5003);
A3=A_MAV;
C3=C_MAV(1:5003);
R3=R_MAV(1:5003);
A4=AnWT;
C4=CWT(1:5003);
R4=RWT(1:5003);
for i=1:5003
ACR_L=[ACR_L; 'A'];
end
for j=1:5003

```

```

ACR_L=[ACR_L; 'C'];
end
for k=1:5003
ACR_L=[ACR_L; 'R'];
end
ACR_MA=[A;C;R]; %Para entrenar
ACR_RMS=[A2;C2;R2];
ACR_MAV=[A3;C3;R3];
ACR_WT=[A4;C4;R4];
T = table(ACR_MA,ACR_RMS,ACR_MAV,ACR_WT,ACR_L);
ACR=[Comb]; %Para clasificar nuevos datos
T2 = table(ACR);
yfit = trainedClassifierRMS.predictFcn(T2)

```